

**UNIVERSIDADE ESTADUAL DE CAMPINAS  
FACULDADE DE ENGENHARIA CIVIL**

**Modelagem Chuva-Vazão em Bacias  
Hidrográficas com Suporte em Redes Neurais  
Artificiais**

**Ana Rosa Baganha Barp**

**Campinas,SP**

**1999**

**UNIVERSIDADE ESTADUAL DE CAMPINAS**  
**FACULDADE DE ENGENHARIA CIVIL**

**Modelagem Chuva-Vazão em Bacias Hidrográficas com Suporte em**  
**Redes Neurais Artificiais**

**Ana Rosa Baganha Barp**

**Orientador: Prof. Dr. Paulo Sérgio Franco Barbosa**

Tese de Doutorado apresentada à Comissão de pós-graduação da Faculdade de Engenharia Civil da Universidade Estadual de Campinas, como parte dos requisitos para obtenção do título de Doutora em Engenharia Civil, na área de concentração Recursos Hídricos.

**Campinas,SP**

**1999**

UNIDADE	BC
Nº CHAMADA	
V	EX
TOMBO BC/	68632
PROC.	16.123.06
C	<input type="checkbox"/>
D	<input checked="" type="checkbox"/>
PREÇO	11,00
DATA	02/06/06

FICHA CATALOGRÁFICA ELABORADA PELA  
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

B268m Barp, Ana Rosa Baganha  
Modelagem chuva-vazão em bacias hidrográficas com  
suporte em redes neurais artificiais / Ana Rosa Baganha  
Barp.--Campinas, SP: [s.n.], 1999.

Orientador: Paulo Sérgio Franco Barbosa.  
Tese (doutorado) - Universidade Estadual de  
Campinas, Faculdade de Engenharia Civil.

1. Recursos hídricos - Desenvolvimento. 2.  
Otimização matemática. 3. Análise de sistemas. 4.  
Inteligência artificial. 5. Redes neurais (Computação).  
6. Bacias hidrográficas. I. Barbosa, Paulo Sérgio Franco.  
II. Universidade Estadual de Campinas. Faculdade de  
Engenharia Civil. III. Título.

**UNIVERSIDADE ESTADUAL DE CAMPINAS  
FACULDADE DE ENGENHARIA CIVIL**

**Modelagem Chuva-Vazão em Bacias Hidrográficas com Suporte em  
Redes Neurais Artificiais**

**Ana Rosa Baganha Barp**

Tese de Doutorado aprovada pela Banca Examinadora, constituída por:

Prof. Dr. Paulo Sérgio Franco Barbosa  
Presidente e Orientador/ FEC-UNICAMP

Prof. Dr. Rubem La Laina Porto  
Poli-USP

Prof. Dr. Takaaki Ohishi  
FEE-UNICAMP

Prof. Dr. Valter Hernandez  
FEC-UNICAMP

Prof. Dr. Antônio Carlos Zuffo  
FEC-UNICAMP

Atesto que esta é a versão definitiva  
da dissertação de Ana Rosa Baganha Barp  
16/10/2005  
Prof. Dr.   
Matrícula: 069922

Campinas, 06 de dezembro de 1999

200611258

*A Wilson,  
pelo incentivo e companheirismo.  
A Kauê e Luana,  
pela afetividade e estímulo à vida.*

## **Agradecimentos**

Ao Professor Dr. Paulo Sérgio Franco Barbosa, por sua dedicação e clareza na orientação do trabalho, especialmente por ter acreditado e estimulado o emprego de técnica não convencional para simular o sistema hidrológico em estudo, e manter-se sempre pronto para dialogar, sugerir e nunca impor, proporcionando assim um clima cordial de estudo.

Aos professores e aos funcionários da Faculdade de Engenharia Civil, que me deram apoio durante o programa de pós-graduação e pela atenção e préstimos durante os anos de convivência.

Aos funcionários da Biblioteca da Área de Engenharia - BAE, de quem obtive ajuda no levantamento bibliográfico.

À Fapesp pelo apoio financeiro.

Aos colegas de curso que, nesses anos de convívio, demonstraram amizade e companheirismo.

Ao Professor Dr. Fernando José Von Zuben e a doutoranda Rosângela Ballini, pelos elucidamentos e importantes sugestões na elaboração do modelo de redes neurais artificiais.

Ao Engenheiro João Eduardo Lopes, autor do programa SMAPm, por seus esclarecimentos pertinentes ao desempenho do modelo, sua gentileza e atenção.

À Fundação Centro Tecnológico de Hidráulica da Universidade de São Paulo que forneceu-me os dados hidrológicos e cartográficos.

À Agência Nacional de Energia Elétrica por ter prestado no envio de parte dos dados usados na tese.

Aos meus pais Luiz e Anita, meus irmãos Luiz Junior e Luiz Thadeu, pelo incentivo e ajuda nas horas difíceis.

Ao Wilson que por meio de nosso relacionamento afirmou nosso valor verdadeiro e que nos ajudou a crescer e a realizar nosso potencial.

Aos meus filhos, Kauê e Luana, pelo sentido da vida; embora em alguns momentos de trabalho, necessitei ausentar-me de nosso convívio.

*Why does this magnificent applied science which saves work and makes life easier bring us so little happiness? The simple answer runs: we have not yet learned how to make sensible use of it.*

Albert Einstein (1879-1955)

## Resumo

Barp, Ana Rosa Baganha. Modelagem Chuva-Vazão em Bacias Hidrográficas com Suporte em redes Neurais Artificiais. Campinas, Faculdade de Engenharia Civil, Universidade Estadual de Campinas, 1999. 271 Páginas. Tese (Doutorado)

Este trabalho investiga a utilização de modelos determinísticos de simulação hidrológica do tipo chuva-vazão, cuja área de estudo refere-se as bacias dos rios Itapetininga, das Almas e Guarapiranga no estado de São Paulo e bacia do rio Guaporé no estado de Mato Grosso. São testados dois modelos determinísticos do tipo chuva-vazão, ambos com processo de otimização dos parâmetros na forma irrestrita e não linear : SMAP (*Soil Moisture Accounting Procedure*) - com aplicação de um método de otimização de primeira ordem; e outro modelo utilizando a técnica de Redes Neurais Artificiais (RNA's), com método de otimização de segunda ordem. Em ambos os casos é tomado o intervalo de discretização mensal. A concepção testada sobre a posição de inserção do modelos de RNA's acoplado ao SMAP, tem origem na necessidade de investigação do potencial das RNA's em substituição aos parâmetros e processos tradicionais dos modelos chuva-vazão e, representada diretamente a relação chuva-vazão, partindo-se portanto, como entrada a série de precipitações e gerando-se as vazões através da RNA.

**Palavras Chave:** Recursos hídricos – Desenvolvimento, Otimização matemática, Análise de sistemas, Inteligência artificial, Redes neurais (Computação), Bacias hidrográficas.

## Sumário

	Página
Resumo	vii
Lista de Tabelas	xii
Lista de Figuras	xiv
Listas de Gráficos	xvi
Lista de Quadros	xix
<b>Capítulo I – Introdução.....</b>	<b>1</b>
1.1 Redes Neurais Artificiais Aplicadas a Modelos Hidrológicos.....	1
1.2 Objetivo do Trabalho.....	3
1.3 Justificativa.....	4
1.4 Organização do Trabalho.....	5
<b>Capítulo II – Modelos de Simulação Hidrológica.....</b>	<b>7</b>
2.1 As Origens e a Importância da Simulação.....	7
2.2 O Ciclo Hidrológico.....	8
2.3 Desenvolvimento dos Modelos.....	10
2.3.1 Modelos de Simulação.....	11
2.3.2 Incertezas dos Resultados da Simulação.....	33
2.4 Modelos de Gerenciamento de Recursos Hídricos.....	36
2.4.1 Modelos de Simulação Chuva-Vazão.....	36
2.4.1.1 Modelo Determinístico Conceitual Chuva-Vazão.....	40

<b>Capítulo III – Redes Neurais Artificiais.....</b>	<b>42</b>
3.1 Introdução.....	42
3.2 Otimização de Sistemas.....	44
3.2.1 Métodos de Otimização.....	44
3.2.1.1 Métodos Diretos.....	47
3.3 Fundamentos de RNA's.....	63
3.3.1 O Neurônio Artificial.....	67
3.3.2 Topologia das RNA's.....	68
3.3.3 Rede do Tipo Perceptron Multicamada (MLP.....	72
3.4 Processo de Aprendizagem e Generalização.....	75
3.4.1 Normalização.....	78
3.4.2 Aprendizado Supervisionado.....	80
3.4.3 Regra de Aprendizagem de Correção do Erro.....	81
3.4.4 Modos de Treinamento de RMC.....	89
3.4.5 Inicialização dos Pesos.....	92
3.4.6 Taxa de Aprendizagem.....	94
3.4.7 Critério de Parada.....	95
3.4.8 Validação Cruzada.....	96
3.4.9 Generalização.....	97
3.5 Simuladores de RNA's.....	98
<b>Capítulo IV – Modelo Conceitual de Simulação Chuva-Vazão Utilizando RNA's... 100</b>	<b>100</b>
4.1 Descrições das Situações Objetos de Pesquisa.....	100
4.2 Modelo de Simulação Hidrológica – SMAPm.....	102
4.2.1 Descrição do Modelo SMAPm.....	103
4.2.2 Metodologia de Calibração.....	113
4.3 Algoritmo Proposto para Simulação Chuva-Vazão através de RNA's.....	120
4.3.1 Justificativa para a Proposição do Algoritmo de RNA.....	120
4.3.2 Topologia da Rede Proposta.....	128
<b>Capítulo V – Estudo de Caso.....</b>	<b>129</b>

5.1	Introdução.....	129
5.2	Alguns Aspectos Fisiográficos da Área de Estudo.....	130
5.3	Metodologia de Avaliação dos Resultados dos Modelos.....	132
5.3.1	Modelo SMAPm.....	133
5.3.2	Modelo de RNA's.....	136
5.3.3	Avaliação Estatística dos Resultados.....	140
5.4	Simulação do Modelo SMAPm.....	146
5.4.1	Programação.....	146
5.4.2	Resultados.....	150
5.5	Simulação do Modelo em RNA's.....	154
5.5.1	Programação.....	155
5.5.2	Resultados.....	157
5.5.2.1	Bacia do Rio Itapetininga.....	158
5.5.2.2	Bacia do Rio das Almas.....	163
5.5.2.3	Bacia do Rio Guarapiranga.....	167
5.5.2.4	Bacia do Rio Guaporé.....	171
5.6	Análise dos Resultados.....	174
5.6.1	Resultados.....	175
5.6.1.1	Bacia do Rio Itapetininga.....	176
5.6.1.2	Rio da Bacia do Rio das Almas.....	178
5.6.1.3	Rio da Bacia do Rio Guarapiranga.....	179
5.6.1.4	Bacia do Rio Guaporé.....	181
5.6.2	Avaliação Estatística dos Resultados.....	182
5.6.3	Síntese da Avaliação dos Resultados.....	186
	<b>Capítulo 6 – Conclusões e Recomendações.....</b>	<b>194</b>
6.1	Conclusões.....	194
6.2	Recomendações.....	197
	Anexos.....	198
	Referências Bibliográficas.....	239

Bibliografias Consultadas	247
Abstract	256
Apêndice	257

## Lista de Tabelas

	Página
Tabela 4.1 - Parâmetro de Calibração da Constante de Recessão, k	114
Tabela 5.1 - SMAP - Divisão dos Períodos de Dados para Simulação	135
Tabela 5.2 - Postos Pluviométricos Selecionados	136
Tabela 5.3 – Postos Fluviométricos e Evaporimétricos Selecionados	136
Tabela 5.4 -RNA - Divisão dos Períodos de Dados para Simulação	139
Tabela 5.5 – Bacia do Rio Itapetininga – Calibração e Validação: Erro Quadrático	158
Tabela 5.6 – Bacia do Rio das Almas – Calibração e Validação: Erro Quadrático	163
Tabela 5.7 – Bacia do Rio Guarapiranga – Calibração e Validação: Erro Quadrático	167
Tabela 5.8 – Bacia do Rio das Almas – Calibração e Validação: Erro Quadrático	171
Tabela 5.9 – Bacia do Rio Itapetininga – Validação RNA e SMAP: Vazão Média, Desvio Padrão, Correlação e Variância	176
Tabela 5.10 – Bacia do Rio Itapetininga - Valores Calculados dos Critérios AIC e BIC para as Topologias de RNA e o Modelos SMAP	176
Tabela 5.11 – Bacia do Rio Itapetininga - Comparação Estatística entre os Resultados dos Modelos de RNA e SMAP	177
Tabela 5.12 – Bacia do Rio das Almas – Validação RNA e SMAP: Vazão Média, Desvio Padrão, Correlação e Variância	178
Tabela 5.13 – Bacia do Rio das Almas - Valores Calculados dos Critérios AIC e BIC para as Topologias de RNA e o Modelos SMAP	178
Tabela 5.14 – Bacia do Rio das Almas - Comparação Estatística entre os Resultados dos Modelos de RNA e SMAP	179

Tabela 5.15 – Bacia do Rio Guarapiranga – Validação RNA e SMAP: Vazão Média, Desvio Padrão, Correlação e Variância	179
Tabela 5.16 – Bacia do Rio Guarapiranga - Valores Calculados dos Critérios AIC e BIC para as Topologias de RNA e o Modelos SMAP	180
Tabela 5.17 – Bacia do Rio Guarapiranga - Comparação Estatística entre os Resultados dos Modelos de RNA e SMAP	180
Tabela 5.18 – Bacia do Rio Guaporé – Validação RNA e SMAP: Vazão Média, Desvio Padrão, Correlação e Variância	181
Tabela 5.19 – Bacia do Rio Guaporé - Valores Calculados dos Critérios AIC e BIC para as Topologias de RNA e o Modelos SMAP	181
Tabela 5.20 – Bacia do Rio Guaporé - Comparação Estatística entre os Resultados dos Modelos de RNA e SMAP	182
Tabela 5.21 – Hierarquia de Melhores Resultados dos Modelos em Cada Bacia Segundo Inspeção Visual – Etapa de Validação	187
Tabela 5.22 – Duplas de Modelos com Melhores Desempenhos em cada Bacia, Segundo Avaliação de cada Critério (Período de Validação)	189
Tabela 5.23 – Modelos de Melhor Desempenho para cada Bacia – Etapa de Validação	191
Tabela 5.24 – Comparação dos RMSE de modelos RNA – caso 1 para Diferentes Bacias (Fase de Validação)	192

## Lista de Figuras

	Página
Figura 2.1 - Desenho Esquemático do Ciclo Hidrológico	9
Figura.2.2 - Representação Esquemática da Entrada e Saída de uma Série Temporal em Relação a um Dinâmico Simples	12
Figura.2.3 - Desenho Esquemático da Simulação da Bacia: Fase Terra	15
Figura 2.4 - Metodologia sugerida para selecionar um modelo matemático	18
Figura 2.5 - Subdivisão da Amostra Teste	25
Figura 2.6 - Amostra Teste Diferencial	25
Figura 3.1 - Posto Estacionário da Função de Única Variável Plurimodal, $F(x_1)$	49
Figura 3.2 - Restrição Atuante	49
Figura 3.3 - Ilustrações de Figuras Estritamente Convexa, Convexa e Não Convexa	51
Figura 3.4 - Projeção do Vetor Gradiente no Ponto $x$ , num Problema de Maximização	54
Figura 3.5 - Fluxograma Esquemático do Método de Rosenbrock	57
Figura 3.6 – Estrutura Geral do Neurônio Biológico Genérico	67
Figura 3.7 - Elementos de Conexão de RNA's	68
Figura 3.8 - Arquitetura de um Neurônio Artificial com Múltiplas Entradas Não Lineares	69
Figura 3.9 - Tipos de Funções de Ativação	70
Figura 3.10 - Representação Funcional de um Neurônio – Perceptron de McCulloch e Pitts	73
Figura 3.11 – Arquitetura de Rede Neural Multicamadas	74
Figura 3.12 - Taxionomia do Processo de Aprendizagem	77
Figura 3.13 – Estágios de Pré e Pós-processamento de Rede Neural	79
Figura 3.14 – Treinamento Supervisionado de uma RNA	81

Figura 3.15 – Direções de Propagações do Sinal Funcional e do Erro	82
Figura 3.16 – Superfície de Erro	83
Figura 3.17- – Superfície de Erro - Mínimo Local	92
Figura 3.18- – Superfície de Erro - Mínimo Global	93
Figura 3.19 – Taxas de Aprendizagem Globais	94
Figura 4.1 - Arquitetura do Modelo SMAPm na Versão Mensal	104
Figura 4.2 - Representação de Reservatórios para o Balanço de Umidade do Solo	108
Figura 4.3 - Notação Abreviada de uma Rede de Neurônios com Multicamadas	120
Figura 4.4- Notação de Rede Neural Artificial	122
Figura 4.5- Caso1: Relação Direta Precipitação-Vazão por RNA (um Posto Pluviométrico)	124
Figura 4.6 - Caso 2: Relação Precipitação-Escoamento por SMAP e Escoamento-Vazão por RNA	125
Figura 4.7 - Caso 3: Relação Precipitação-Volume por SMAP e Volume-Vazão por RNA	126
Figura 4.8 – Caso4: Relação Direta Precipitação-Vazão por RNA (dois Postos Pluviométricos)	127
Figura 5.1 - Brasil - Desenho Esquemático da Divisão das Bacias Hidrográficas	130
Figura 5.2 - Brasil - Divisão das Bacias Hidrográficas 1 e 6	131
Figura 5.3 – SMAPm - Seleção do Arquivo	147
Figura 5.4 – SMAPm - Procedimento de Análise de Sensibilidade	148
Figura 5.5 – SMAPm - Procedimento de Calibração	149
Figura 5.6 – SMAPm - Ajuste Manual dos Parâmetros e Variáveis de Inicialização	150
Figura 5.7 - Desenho esquemático do uso de pré-processamento e pós-processamento dos dados em conjunto com o mapeamento de RNA	155

## Lista de Gráficos

	Página
Gráfico 5.1 – Bacia do Rio Itapetininga – Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s) – Validação 1 – Período 1986 a 1988	151
Gráfico 5.2– Bacia do Rio Itapetininga – Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s) – Validação 2 – Período 1989 a 1991	152
Gráfico 5.3– Bacia do Rio das Almas – Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s) – Validação 1 – Período 1978 a 1991	152
Gráfico 5.4– Bacia do Rio Guarapiranga – Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s) – Validação 1 – Período 1978 a 1985	153
Gráfico 5.5– Bacia do Rio Guarapiranga – Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s) – Validação 2 – Período 1986 a 1993	153
Gráfico 5.6– Bacia do Rio Guaporé – Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s) – Validação 1 – Período 1977a 1978	154
Gráfico 5.7– Bacia do Rio Itapetininga – Caso1 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s) – Validação Topologia (1,3,1)- – Período 1987 a 1991	159
Gráfico 5.8– Bacia do Rio Itapetininga – Caso1 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s) – Validação Topologia (1,7,1)- – Período 1987 a 1991	159
Gráfico 5.9– Bacia do Rio Itapetininga – Caso2 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,3,1)- – Período 1987 a 1991	160
Gráfico 5.10 – Bacia do Rio Itapetininga – Caso2 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,7,1)- – Período 1987 a 1991	160
Gráfico 5.11 – Bacia do Rio Itapetininga – Caso3 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (2,3,1)- – Período 1987 a 1991	161

Gráfico 5.12 – Bacia do Rio Itapetininga – Caso3 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (2,7,1)- – Período 1987 a 1991	161
Gráfico 5.13 – Bacia do Rio Itapetininga – Caso3 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (2,3,1)- – Período 1987 a 1991	162
Gráfico 5.14 – Bacia do Rio Itapetininga – Caso3 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (2,7,1)- – Período 1987 a 1991	162
Gráfico 5.15 – Bacia do Rio das Almas – Caso1 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,3,1)- – Período 1978 a 1980	163
Gráfico 5.16 – Bacia do Rio das Almas – Caso1 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,7,1)- – Período 1978 a 1980	164
Gráfico 5.17 – Bacia do Rio das Almas – Caso2 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,3,1)- – Período 1978 a 1980	164
Gráfico 5.18 – Bacia do Rio das Almas – Caso2 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,7,1)- – Período 1978 a 1980	165
Gráfico 5.19 – Bacia do Rio das Almas – Caso3 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (2,3,1)- – Período 1978 a 1980	165
Gráfico 5.20 – Bacia do Rio das Almas – Caso3 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (2,7,1)- – Período 1978 a 1980	166
Gráfico 5.21 – Bacia do Rio das Almas – Caso4 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (2,3,1)- – Período 1978 a 1980	166
Gráfico 5.22 – Bacia do Rio das Almas – Caso4 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (2,7,1)- – Período 1978 a 1980	167
Gráfico 5.23 – Bacia do Rio Guarapiranga – Caso1 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,5,1)- – Período 1984 a 1993	168
Gráfico 5.24 – Bacia do Rio Guarapiranga – Caso1 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,7,1)- – Período 1984 a 1993	168
Gráfico 5.25 – Bacia do Rio Guarapiranga – Caso2 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,5,1)- – Período 1984 a 1993	169
Gráfico 5.26 – Bacia do Rio Guarapiranga – Caso2 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,7,1)- – Período 1984 a 1993	169

Gráfico 5.27 – Bacia do Rio Guarapiranga – Caso3 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (2,5,1)- – Período 1984 a 1993	170
Gráfico 5.28 – Bacia do Rio Guarapiranga – Caso3 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (2,7,1)- – Período 1984 a 1993	170
Gráfico 5.29 – Bacia do Rio Guaporé – Caso1 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,7,1)- – Período 1977 a 1978	171
Gráfico 5.30 – Bacia do Rio Guaporé – Caso1 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,10,1)- – Período 1977 a 1978	172
Gráfico 5.31 – Bacia do Rio Guaporé – Caso2 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,7,1)- – Período 1977 a 1978	172
Gráfico 5.32 – Bacia do Rio Guaporé – Caso2 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (1,10,1)- – Período 1977 a 1978	173
Gráfico 5.33 – Bacia do Rio Guaporé – Caso3 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (2,7,1)- – Período 1977 a 1978	173
Gráfico 5.34 – Bacia do Rio Guaporé – Caso3 - Hidrograma das Vazões Médias Mensais (m <sup>3</sup> /s)– Validação Topologia (2,10,1)- – Período 1977 a 1978	174

## Lista de Quadros

	Página
Quadro 2.1 - Classificação dos Sistemas e dos Modelos Baseados na Descrição do Processo	16
Quadro 2.2 - Fases da Simulação de Modelos	18
Quadro 2.3 - Classificação dos Simuladores	22
Quadro 2.4 - Principais Fontes de Incerteza na Simulação de Vazões com Uso de Modelos Chuva-Vazão	34
Quadro 2.5 - Modelos Hidrológicos dos Tipos Caixa-Preta e Conceitual	39
Quadro 3.1 - Teste dos Pontos Estacionários $F(x^*)$	50
Quadro 3.2 - Algoritmos de Otimização Aplicados em Treinamento da Rede	60
Quadro 3.3 – Simuladores de RNA's	99

# CAPÍTULO I

## INTRODUÇÃO

### **1.1 Redes Neurais Artificiais Aplicadas a Modelos Hidrológicos**

Redes neurais artificiais (RNA's), também chamadas na linguagem científica de modelos matemáticos de redes neurais, constituem-se de algoritmos de processamento numérico e computacional que vêm sendo objeto de intensa pesquisa e desenvolvimento recente, diante da capacidade de tratamento de grande número de informações, adaptação a sistemas e processos de natureza diversificada bem como, capacidade de representação de processos complexos que incluem não linearidades e descontinuidades. O objetivo inicial desses modelos era reproduzir, o mais próximo possível, os mecanismos de transmissão de informações do cérebro humano, quanto às tarefas de tomar decisões, processar, aprender, lembrar e otimizar as informações. Mas as pesquisas até aqui desenvolvidas ainda prosseguem no aperfeiçoamento da técnica, obviamente à muita distância da pretensa similaridade funcional completa com o modelo do cérebro humano.

O grande potencial dessa ferramenta já vem sendo comprovado em diversos trabalhos, quando aplicado na análise e síntese de sistemas não lineares, cujo processo subjacente à transformação das variáveis desde a entrada até a saída do sistema não é bem conhecida, ou, mesmo que conhecida, é de elevada complexidade. As áreas de comprovado reconhecimento dessa técnica são: reconhecimento de padrões, teoria da informação, teoria de aproximação de função, teoria de processamento de sinais, previsão de séries temporais, teoria de controle de processos e otimização de sistemas.

A motivação para o desenvolvimento do trabalho aqui apresentado se deu inicialmente por três características da modelagem por RNA: (a) a possibilidade de calibração automática dos parâmetros de um processo de entrada e saída; (b) a vantagem competitiva das RNA para modelagem dos processos em que estão presentes relações não lineares entre as variáveis; (c) a exigência de menor extensão de série histórica para calibração de parâmetros.

A técnica de RNA apresenta grande competitividade com os métodos de modelagem e previsão com hipóteses lineares sobre a relação entre parâmetros e variáveis (ex. ANOVA, Box-Jenkins, Regressão). Os métodos apresentados não requerem a definição dos parâmetros pelo usuário e possuem propriedades de estabilidade e convergência numérica bem definidas. Tais aspectos vêm sendo relatados em diversos estudos anteriores, como em TANG et al. (1990) onde, através da comparação entre os modelos de RNA e os de Box-Jenkins, conclui-se pela superioridade dos resultados derivados das RNA e ainda, a exigência de menor extensão da série observada para garantir a mesma qualidade das previsões. Um segundo estudo comparativo mais completo é relatado em HILL et al. (1996), onde os resultados indicam que a vantagem competitiva das RNA, enquanto técnica de previsão, se dá em séries temporais com intervalos mensais, com número de observações menor que 50 e decorrentes de processos com alta incidência de não linearidades e descontinuidades. Tais trabalhos foram desenvolvidos em séries de natureza diversificada (ex. preços de produtos; demanda por bens de consumo, etc.), porém os atrativos foram suficientes para a proposição do trabalho de pesquisa que se desenvolveu e aqui se apresenta, uma vez que: (a) as séries hidrológicas de vazões fluviais são produto da interação complexa dos processos de transformação chuva-vazão, os quais se representam mais apropriadamente através de relações de natureza não linear e onde também incidem

descontinuidades; (b) a extensão das séries hidrológicas também constitui um fator limitante à aplicação de muitos modelos, tornando valiosas as técnicas que permitem extrair o máximo de informação de registros escassos.

Dentre as opções de modelagem do processo chuva-vazão, optou-se inicialmente por investir na concepção de um modelo do tipo conceitual com base na representação física dos processos que ocorrem no ciclo hidrológico, o qual deveria ser estruturado na forma de redes neurais sendo os parâmetros determinados pela etapa de *aprendizagem* da rede. Os modelos que utilizam a otimização tradicional e a simulação requerem razoável experiência do hidrólogo, especialmente na fase de calibração dos parâmetros. Já com a técnica de RNA a participação do usuário seria reduzida, bem como poderia ser reduzida, também, a margem de erro entre os resultados observados e os calibrados pelo modelo. Porém, tal concepção se revelou inviável pela própria formatação sistemática requerida pela modelagem em redes neurais, com o conceito de camadas e parâmetros bastante rígidos, sem possibilidade de associação dos mesmos à qualquer parâmetro físico que pudesse ter em correspondência um processo do ciclo hidrológico.

A pesquisa exigiu então um redirecionamento, o que foi feito com base nas primeiras publicações que surgiram na literatura relatando aplicações na área hidrológica (HSU et. al., 1995; SMITH e ELI, 1995). Sendo trabalhos recentes na época, elas indicavam resultados iniciais promissores e sobretudo, espaço e necessidade de aprofundamento da pesquisa no tema. O mesmo se concluiu da leitura das primeiras aplicações da técnica às bacias do Brasil conforme apresentado por SOUZA et. al.(1995) e SARMENTO (1996). Foi neste contexto que surgiram os objetivos da pesquisa, a serem relatados adiante.

## 1.2 Objetivo do Trabalho

Este trabalho tem como objetivo investigar a adequação da utilização de modelos de redes neurais artificiais (RNA) para representar a relação chuva-vazão de bacias hidrográficas. Além do desenvolvimento e identificação da melhor estrutura de redes neurais para representação

de tal processo hidrológico, estuda-se o desempenho da rede neural sob grau variado de informação relativo à natureza física do processo de transformação chuva-vazão. Tal estudo lança mão de um modelo conceitual de simulação hidrológica, o SMAP (*Soil Moisture Accounting Procedure*), o qual é usado tanto para o fracionamento dos componentes do ciclo hidrológico quanto como base de referência para comparação de resultados. Em particular, as seguintes questões foram trabalhadas na pesquisa:

1. Em que medida as RNA's podem extrair informação e representar adequadamente o processo chuva-vazão, com finalidade preditiva, tendo como entrada e saída apenas os totais mensais de precipitação e as respectivas vazões médias mensais em diferentes bacias?
2. Em que circunstâncias tal representação é melhor, equivalente ou pior que as abordagens tradicionais, e em especial tendo como referência o modelo de simulação chuva-vazão SMAP?
3. Quais são os recursos existentes para a melhoria do desempenho da representação por redes neurais?
4. Como se comparam os estudos dessa investigação com outros similares?
5. Quando se pode recomendar o emprego das RNA?

### **1.3 Justificativa**

Os objetivos da utilização dos modelos chuva-vazão na área de recursos hídricos incluem: (a) a busca de melhor compreensão do comportamento dos fenômenos hidrológicos da bacia; (b) previsão de cheias e efeitos resultantes da modificação do uso da terra; (c) dimensionamento de obras hidráulicas e; (d) preenchimento de falhas de séries históricas. Tais aplicações, entre outras, justificam os esforços de pesquisa empreendidos nas últimas três décadas na busca da representação do processo de transformação chuva-vazão através de modelos computacionais, denominados modelos de simulação hidrológica ou ainda, modelos conceituais chuva-vazão.

A despeito dos notáveis progressos, persistem dificuldades e pontos abertos à investigação científica. Um deles consiste ainda na própria estruturação do modelo e definição de seus parâmetros, visto que cada vez mais se conhece e se tenta incluir na modelagem a complexa interação entre a fase terrestre e a fase atmosférica, com progressivos avanços no sentido de extensão da modelagem à fase formativa do componente *precipitação*, possível com as observações obtidas através de imagens de satélites e demais recursos de previsão. Uma vez definida a estrutura, resta o clássico problema da decisão sobre a obtenção dos parâmetros do modelo, sujeita a incertezas e erros de estimativa. Algumas incertezas podem ocorrer tanto na fase de calibração manual (tentativa e erro) ou também na fase de calibração automática dos parâmetros.

No contexto das dificuldades citadas, previamente, a técnica de modelagem por RNA oferece uma opção alternativa que se revela promissora a partir de aplicações em diversas áreas, com algumas vantagens em comparação aos métodos de previsão usualmente empregados. Da mesma forma que ocorreu no desenvolvimento de outras abordagens e aplicações bem sucedidas da área de sistemas em Hidrologia, caracteriza-se, pois um estágio inicial de investigação a partir do qual, somando-se diversas outras contribuições, se poderá chegar à sistematização de procedimentos e conclusões sobre as questões que foram colocadas nos objetivos desse trabalho. Evidencia-se, pois a oportunidade e a conveniência da investigação que se desenvolveu, como forma de trazer uma parcela de contribuição a esse esforço mais geral de pesquisa na área.

## 1.4 Organização do Trabalho

Esta tese está estruturada em 6 capítulos, 9 anexos e um apêndice, constituindo o conteúdo deste trabalho.

Modelos de simulação hidrológica é o título do capítulo 2, e trata de uma descrição resumida das origens e importância da simulação dos processos dinâmicos do ciclo hidrológico. Diante do universo dos modelos desenvolvidos para a simulação dos fluxos hídricos, a ênfase é

---

dada àqueles cuja a aplicação está voltada ao gerenciamento destes recursos, particularmente ao modelo determinístico conceitual chuva-vazão, referente à fase terrestre do ciclo hidrológico.

No capítulo 3 – Redes Neurais Artificiais, uma breve abordagem é apresentada sobre os métodos diretos de otimização como parte introdutória para a teoria de redes neurais artificiais e o respectivo treinamento supervisionado de redes do tipo perceptron de múltiplas camadas. Comentários são atribuídos aos algoritmos de otimização não linear no treinamento destas redes, que são objeto de aplicação ao modelo de simulação hidrológica proposto.

O modelo de simulação chuva-vazão denominado SMAP, desenvolvido por LOPES et al. (1981), é descrito no capítulo 4 - Modelo Conceitual de Simulação Chuva-Vazão Utilizando RNA's, incluindo a formulação teórica, os algoritmos que fazem parte da simulação, a metodologia de calibração e a execução do aplicativo. Na seqüência do mesmo capítulo é destacada a topologia da rede de perceptron com múltiplas camadas e a descrição do algoritmo proposto para simulação chuva-vazão através de RNA's.

O capítulo 5 descreve, inicialmente, alguns aspectos fisiográficos da região em que se inserem as bacias selecionadas para estudo. Posteriormente, a metodologia é aplicada, seguindo-se a avaliação pormenorizada e as discussões dos resultados.

As conclusões e as recomendações, selecionadas com base nos procedimentos realizados ao longo do trabalho, estão itemizadas no capítulo 6. Nos anexos encontram-se as listagens das rotinas dos programas utilizadas para executar o modelo SMAP e o de redes neurais artificiais. No apêndice encontra-se a metodologia do algoritmo *Backpropagation*.

## CAPÍTULO II

# MODELOS DE SIMULAÇÃO HIDROLÓGICA

### 2.1 As Origens e a Importância da Simulação

As tentativas de compreender os fluxos de água na natureza remontam à antigüidade. Embora tal compreensão tenha conseguido razoável êxito em alguns componentes do ciclo hidrológico e fenômenos de particular interesse à Engenharia (ex.: equação Chezy para cálculo de vazão em canais, de 1750), a compreensão qualitativa mais ampla e a formulação quantitativa dos processos de fluxo d'água ao longo de todo o ciclo hidrológico, só se desenvolveram mais intensivamente após a década de 50, com o advento do computador digital. A complexa seqüência de fenômenos, traduzida por grande número de variáveis e parâmetros passou a ser objeto de pesquisas visando a sua representação integrada através de programas computacionais, denominados simuladores.

Embora ainda sem precisão equivalente quanto aos resultados obtidos em outras áreas de aplicação, nas quais as variáveis têm melhor precisão de medida e controle (ex.: simulação de

fluxos em circuitos elétricos, simulação de processos químicos em plantas industriais), pode-se assegurar que a simulação hidrológica já trouxe contribuições muito significativas, seja para compreensão do ciclo hidrológico, bem como à melhoria dos processos de decisão em gerenciamento de recursos hídricos.

No âmbito do País, merecem destaque, dentre outros, os benefícios do usos da simulação hidrológica na fase de construção da Usina Hidroelétrica de Tucuruí (PA), quando se evitou o galgamento da ensecadeira (benefício estimado: US\$ 2 bilhões) com base nas previsões de cheias fornecidas pelo modelo SSAAR (*Streamflow Synthesis na Reservoir Regulation*), bem como, os benefícios da operação dos reservatórios de usinas hidroelétricas de empresas geradoras (ex.: Companhia de Eletricidade do Estado de São Paulo (CESP), Companhia de Eletricidade do Estado de Minas Gerais (CEMIG)), os quais se baseiam em modelos de simulação.

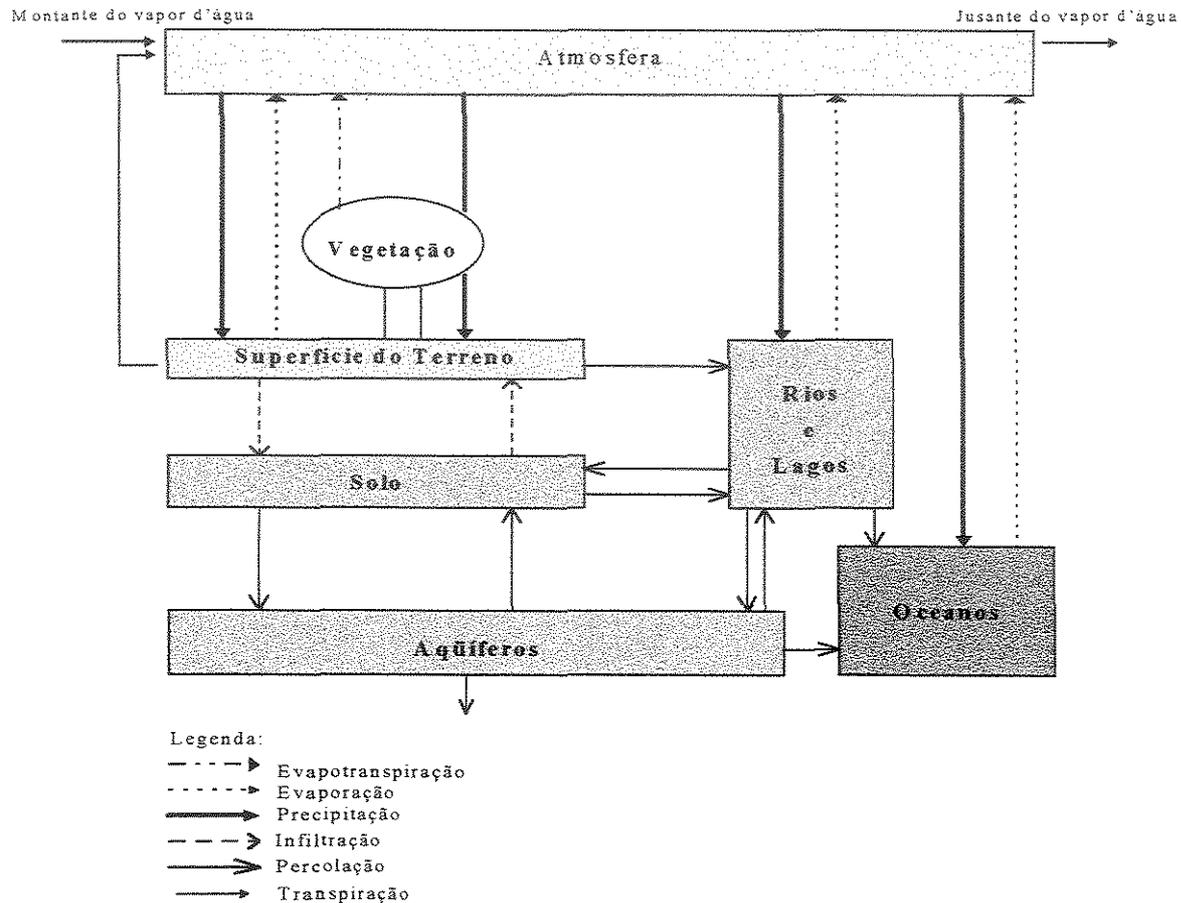
Para que se possa uniformizar a terminologia e garantir a compreensão da representação dos processos a serem objetos de modelagem, apresenta-se a seguir uma breve descrição do ciclo hidrológico, sob o enfoque sistêmico.

## 2.2 O Ciclo Hidrológico

O ciclo hidrológico é um fenômeno global de circulação hermética da água entre a superfície terrestre e a atmosfera, estimulado essencialmente pela energia solar cooptada à gravidade e à rotação terrestre. O ciclo hidrológico é fechado em termos globais na escala terrestre.

O intercâmbio existente entre as circulações da superfície terrestre e da atmosfera ocorre em dois sentidos distintos, a saber: a) no sentido superfície-atmosfera, onde o fluxo de água ocorre fundamentalmente na forma de vapor, como um fenômeno de evaporação e de transpiração, sendo este último um fenômeno biológico; b) no sentido atmosfera-superfície, onde a transferência de água ocorre em qualquer estado físico, sendo mais significativa, as precipitações de chuva e neve.

Conforme a **Figura 2.1**, o ciclo hidrológico é constituído de três estágios correspondentes ao transporte de massa: atmosfera, terra e oceanos.



**Figura 2.1 - Desenho Esquemático do Ciclo Hidrológico**

A partir de cada evento de precipitação ( $P$ ), a água da chuva pode ser interceptada pela vegetação natural (ou evapotranspirada) ou cair diretamente sobre o solo da bacia. A parcela de água que é interceptada, geralmente é de quantidade menor que a precipitação total. Portanto, a parcela de água que atinge a superfície do solo poderá percorrer os seguintes percursos: evaporar, penetrar no solo ou escoar superficialmente.

A água infiltrada sofre o fenômeno da ação de capilaridade, sendo retida nas camadas superiores do solo, se esta prevalecer sobre a força da gravidade. A partir do tempo em que o solo se umedece, a força da gravidade prevalece e a água percola na direção das camadas profundas.

Para calcular o processo de transferência de água através de formulações matemáticas, com fins operacionais, BRAGA e CONEJO (1983) indicam duas fases na simulação do ciclo hidrológico:

1. *Fase solo* ou *terra*, onde se calcula o escoamento de entrada no canal, conhecido por contribuição lateral, e
2. *Fase canal*, onde se processa o “*routing*” quando a contribuição lateral escoar na rede de canais da bacia.

Para a finalidade de tomada de decisão em engenharia, o ciclo hidrológico é descrito de maneira resumida, uma vez que, por ser um fenômeno complexo, torna-se muito extensa uma formulação analítica completa e detalhada.

Entender o processo de transporte de massa e representá-lo de maneira mais aproximada do meio natural, é fundamental na engenharia de recursos hídricos, principalmente, quando o fator tempo é importante no planejamento<sup>1</sup> e tomada de decisões de grandes projetos<sup>2</sup>.

Simular hidrológicamente um sistema, “... *consiste em reproduzir os processos de transporte de massa, que têm nas diferentes etapas do ciclo hidrológico*” (HERMANN, 1980). Portanto, alguns dos modelos que representam estes fenômenos de transporte, aplicados a diversas finalidades de estudo, serão visto a seguir.

## 2.3 Desenvolvimento dos Modelos

Os modelos aplicados no estudo de caso são do tipo simulação chuva-vazão e, para uma compreensão dos mecanismos que envolvem a sua formulação, a partir da concepção de sistema até a sua operacionalização, são descritos de forma sucinta, a seguir, os conceitos de sistemas,

---

<sup>1</sup> Na obtenção de dados de vazões: a série hidrológica do modelo gerado para Tucuruí, só possuía 5 anos.

<sup>2</sup> Na operação de sistemas existentes.

modelos e simulação; aplicações e restrições do modelo; algumas indicações de como construí-lo, bem como suas classificações, passando pelas incertezas na sua modelação.

### 2.3.1 Modelos de Simulação

A pesquisa operacional é um conjunto de técnicas matemáticas empregada na formulação e decisão sobre um problema, objetivando determinar o melhor aproveitamento dos recursos disponíveis, usualmente escassos. Várias são as técnicas matemáticas utilizadas, tais como: programação linear, programação não-linear, programação em redes, programação dinâmica, programação inteira, otimização combinatória, teoria de filas, teoria de decisão, simulação de sistemas, dentre outras.

O emprego da pesquisa operacional justifica-se como um procedimento de auxílio naqueles processos cuja finalidade é a tomada de decisão e o planejamento. As etapas que constituem o processo de aplicação incluem (PERIN FILHO, 1995):

1. Estudar o problema;
2. Identificar o sistema;
3. Construir o modelo;
4. Obter a solução;
5. Operacionalizar a solução, e
6. Realimentar.

A conceituação de PERIN FILHO (1995) para sistema é:

*“... um conjunto estruturado de componentes que interagem de modo regular entre si e com o meio ambiente, satisfazendo a certas restrições ambientais provenientes da escassez de recursos, para atingir determinados objetivos “.*

Independentemente da associação a um objetivo ou tomada de decisão, DOOGE (1967) apud SINGH (1988) conceitua sistema aplicando a seguinte definição matemática:

“... qualquer estrutura, dispositivo, esquema ou procedimento, real ou abstrato, que interrelaciona em um dado tempo de referência, um input, causa ou estímulo da matéria, energia ou transformação e, um output, efeito ou resposta da informação, energia ou matéria”,

isto é, seja  $S$  um sistema definido como sendo um conjunto de pares ordenados de entradas e saídas, usualmente chamados de sinais,

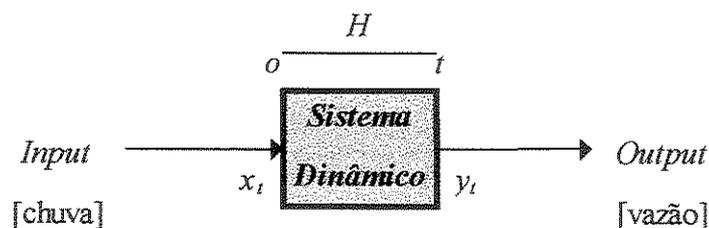
$$S = \{x_i(t), y_i(t)\}, \quad i = 1, 2, 3, \dots \quad (2.1)$$

Em que  $(x_i, y_i)$  denotam os pares ordenados em  $i=1, 2, 3, \dots$

O sistema é composto de entrada  $x(t)$ , que são os membros de domínios de  $S$ ; da saída  $y(t)$ , que são os membros da série de  $S$  e, da operação do sistema ou uma função  $H$  a qual contém uma caracterização matemática de um processo que relaciona as entradas e saídas. Esta função pode ser caracterizada por um operador diferencial, um operador integral, um operador integral-diferencial ou um operador funcional.

Considere um sistema dinâmico simples, representado esquematicamente na **Figura 2.2** (*representação do tipo caixa-preta*), o qual recebe uma entrada  $x$ , uma função de sistema  $H$  (função resposta ao impulso, que determina a função de transferência para um sistema), operando sobre a entrada  $x$  e produzindo uma saída  $y$ , com a relação entre a entrada e saída dada por (BOX e JENKINS, 1976):

$$y = H \cdot x \quad (2.1)$$



**Figura 2.2 - Representação Esquemática da Entrada e Saída de uma Série Temporal em Relação a um Sistema Dinâmico Simples**

Um sistema pode ser representado de forma matemática e caracterizado, quanto a sua linearidade, segundo a equação diferencial ordinária abaixo:

$$A_n \frac{d^n x}{dt^n} + A_{n-1} \frac{d^{n-1} x}{dt^{n-1}} + \dots + A_1 \frac{dx}{dt} + A_0 x = y(t) \quad (2.2)$$

Em que  $x(t)$  é a entrada,  $y(t)$  é a saída e  $A_i$  ( $i = 0, 1, 2, \dots, n$ ) são os coeficientes de (2.2).

Os sistemas são compostos por componentes que são subsistemas e que interagem entre si através das entidades, que representam recursos importantes os quais fluem de um componente para o outro. Cada sistema possui características próprias, genericamente um sistema

- consiste em mais de um componente;
- estes componentes são separados; eles podem ser interdependentes;
- estes componentes são postos juntos seguindo a mesma escolha de esquema. Isto é, um sistema é um arranjo ordenado;
- um sistema interrelaciona entrada e saída, causa e efeito, ou estímulo e resposta;
- a resposta desta interrelação é uma função principal de um sistema; a ênfase sobre a função do sistema é sobre a sua estrutura;
- um sistema não requer que a entrada e a saída sejam semelhantes ou possuam a mesma natureza;
- uma entrada pode ser um vetor ou pode ser completamente distribuída no tempo e no espaço, e
- um sistema pode ser real ou abstrato.

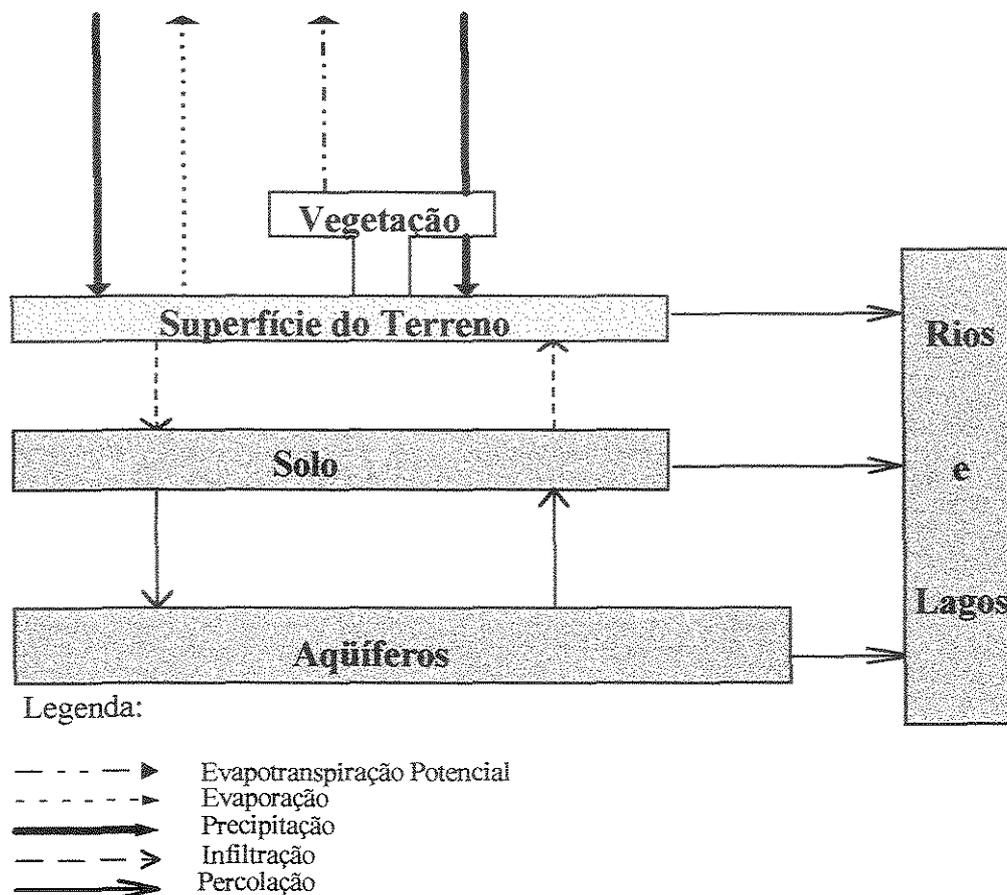
A estratégia, aplicada para solução de um problema, pode ser seguida de três procedimentos (PERIN FILHO, 1995):

- a) *Experimentação direta*: é um processo pelo qual se promove um experimento sobre o sistema real e a partir desta escolhe-se a melhor solução por meio de tentativa e erro;

- b) *Resolução analítica*: inicialmente constrói-se um modelo analítico com a utilização de algum método matemático adequado e, conseqüentemente, obtém-se uma solução para o problema em estudo, e
- c) *Simulação de sistemas*: o sistema real é simulado a partir do desenvolvimento de um programa de computador; através deste os experimentos são realizados com o objetivo de se eleger o melhor resultado por meio de tentativa e erro.

O sistema a ser simulado, no estudo de caso, é o ciclo hidrológico de uma dada bacia nas regiões Sudeste e Centro-Oeste. Vários são os componentes de seu sistema, incluindo precipitação, interceptação, evaporação, transpiração, infiltração, detenção ou retenção de armazenagem, escoamento superficial, escoamento subsuperficial e escoamento subterrâneo. Os subsistemas que constituem o sistema hidrológico são o sistema de escoamento superficial, o sistema de umidade do solo, o sistema de água subterrânea e o sistema fluvial.

Na **Figura 2.3**, que representa o processo de transporte de massa hídrica de uma bacia, foram excluídas três etapas, as circulações atmosféricas, fluviais e lacustres e oceânicas, tratando-se apenas da estrutura básica de integração dos processos relacionados ao balanço vertical dos fluxos e ao escoamento da bacia.



*Figura 2.3 - Desenho Esquemático da Simulação da Bacia: Fase Terra*

O *modelo* é a representação de forma simplificada do comportamento de um sistema. São de diferentes tipos, assim como são desenvolvidos com vista a diferentes propostas. Diversos modelos compartilham estruturas similares, em função da subordinação de suas hipóteses serem as mesmas, e outros modelos são diferentes distintamente. Para se obter maior êxito no processo de modelagem, são acrescentadas as características da bacia e do rio, a familiaridade com o modelo e o objetivo do projeto.

A classificação dos sistemas e modelos está conceituada no **Quadro 2.1**.

**Quadro 2.1 - Classificação dos Sistemas e dos Modelos Baseados na Descrição do Processo**

<b>Sistemas</b>		
<b>Linear ou</b>	<b>Variante ou</b>	Um sistema é linear quando as propriedades de superposição e homogeneidade são satisfeitas (Cheng, 1959). A partir da equação diferencial ordinária, podemos classificar o sistema em linear invariante no tempo (o coeficiente é constante - $A_i = cte$ ); Variante no tempo (o coeficiente varia no tempo - $A_i = f_i(t)$ ); Não linear (o coeficiente é função da saída - $A_i = f_i(x)$ ).
	<b>Invariante</b>	
<b>Não linear</b>		
<b>Contínuo ou</b>		Para um sistema ser considerado contínuo os fenômenos físicos são contínuos no tempo. Sistemas ditos discretos ocorrem mudanças de estados em intervalos discretos.
<b>Discreto</b>		
<b>Concentrado ou</b>		Quando os parâmetros e variáveis do sistema variam com tempo, são ditos concentrado ou <i>lumped</i> . Quando variam com o espaço, são chamados de distribuídos ou <i>distributed</i> .
<b>Distribuído</b>		
<b>Modelos</b>		
<b>Estocástico ou</b>		Quando o relacionamento entre entrada e saída é estatístico. Quando, para uma mesma entrada, o sistema produz sempre a mesma saída.
<b>Determinístico</b>		
<b>Conceitual ou</b>		Quando as funções utilizadas na sua elaboração levam em consideração os processos físicos. Também chamado de caixa-preta ( <i>black box</i> ), ajusta os valores calculados aos dados observados através de funções empíricas, que não estão relacionadas com os fenômenos físicos.
<b>Empírico</b>		

Fonte: DOOGE (1973) e TUCCI (1987)

Estes modelos são bastante utilizados no gerenciamento de recursos hídricos e, dentre aqueles existentes<sup>3</sup>, estão selecionados no presente estudo, os modelos do tipo hidrológico<sup>4</sup> que representam o comportamento de uma parte do sistema, preferencialmente, aqueles que simulam a transformação de chuva em vazão.

Outra classificação dos modelos é quanto às escalas temporais e espaciais. A primeira, pode ser definida como combinação de dois intervalos de tempo, sendo que, um intervalo de tempo é usado para cálculos de entrada e internos e, o outro é aplicado à saída e calibração do

<sup>3</sup> Outras áreas de aplicação são a hidráulica, meio ambiente e saneamento.

<sup>4</sup> Outros tipos: precipitação-vazão, vazão-vazão, geração estocástica de vazão, geração estocástica de precipitação e água subterrânea.

modelo. Seguindo esta classificação, os modelos podem ser distinguidos como : a) tempo contínuo ou baseado em evento; b) diários; c) mensais e, d) anuais. O modelo pode requerer intervalos de tempo mais curtos (horários ou menores).

Quanto à classificação, baseada na escala espacial, pode ser aplicado, como critério, modelo para bacias pequenas, de tamanho médio e grande. Dentre as classificações existentes com relação ao tamanho da bacia, SINGH (1995) considera, de maneira arbitrária, para pequenas bacias, como sendo aquelas de área menor ou igual a 100 km<sup>2</sup>, para áreas compreendidas entre 100 a 1.000 km<sup>2</sup> seguem classificação de bacias médias, e aquelas com áreas maiores que 1.000 km<sup>2</sup> são denominadas de grandes bacias. As bacias também podem ser classificadas, segundo o uso do solo: bacias agrícolas, urbanas, florestadas, desertas, montanhosas, costeiras, áridas e mistas.

Freqüentemente, os modelos aplicados a bacias são identificados com base no uso pretendido, tais como modelos de planejamento, modelos de gerenciamento e modelos de previsão. As técnicas matemáticas implementadas na resolução destes modelos constituem-se em métodos numéricos, de otimização, estatísticos e de geoprocessamento.

A construção de um modelo hidrológico trata de um processo bastante complexo, pela necessidade de se resolver um problema particular ou pela investigação científica da construção do modelo, com vista a sua aplicação na solução de um problema. Recomenda-se seguir alguns critérios básicos. Na fase de teste alguns destes critérios incluem: o modelo deve ser suficientemente simples para permitir sua manipulação e entendimento representativo do sistema dentro de uma precisão desejada e suficientemente abrangente para permitir extrapolação de conclusões. As etapas típicas de modelagem são resumidas na **Figura 2.4**.

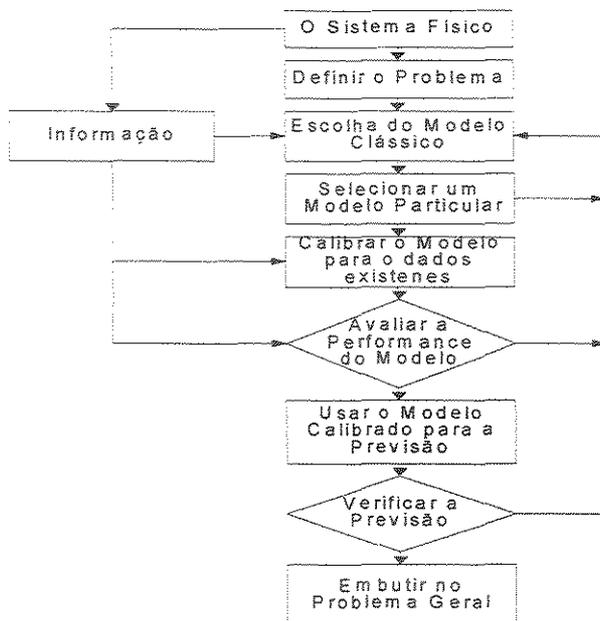


Figura 2.4 - Metodologia Sugerida para Selecionar um Modelo Matemático

Fonte: DOOGE, 1981

Todas essas etapas metodológicas se resumem em três fases as quais constituem o processo de como utilizar um modelo, conceituadas no **Quadro 2.2**.

Quadro 2.2 - Fases da Simulação de Modelos

<i>Fases da Simulação</i>	
<b>1. Ajuste ou Calibração</b>	É a fase da simulação em que os parâmetros devem ser identificados e avaliados.
<b>Estimativa</b>	Na ausência de dados sobre as variáveis do sistema, os valores dos parâmetros são estimados (geralmente em intervalos de variação) com base nas informações retiradas das características físicas do sistema.
<b>Tentativa</b>	A partir dos valores das variáveis de entrada e saída, por tentativa se ajustam os valores dos parâmetros, de tal forma que os valores calculados se aproximem ao máximo dos valores observados.
<b>Otimização</b>	Com base nos dados aplicados pelo processo de tentativa, uma função objetivo é otimizada através de processos matemáticos.
<b>Amostragem</b>	Os valores dos parâmetros são obtidos através de medições específicas no sistema.
<b>2. Verificação/Validação</b>	É a utilização do modelo já calibrado, com dados diferentes daqueles usados no ajuste.
<b>3. Aplicação</b>	É a fase em que o modelo é usado para representar situações onde se desconhece a saída do sistema.

Fonte: TUCCI (1988)

Há duas restrições que podem comprometer os modelos, quanto ao grau de desempenho: recursos computacionais e a base de dados acessível. A melhora da base de dados pode ocorrer com a implementação de recursos modernos de medição em tempo real, através do sensoriamento remoto, aferição de equipamentos, rede hidrometeorológica planejada em pontos estratégicos, diminuindo, dessa forma, as incertezas dos parâmetros calibrados.

As variáveis que compõem os modelos podem ser classificadas conforme apresentado adiante (PERIN FILHO, 1995):

- *Variáveis de estado*: “ O conjunto destas variáveis deve possuir informações suficientes para permitir a execução e o acompanhamento da simulação “. Exemplo: nível de armazenamento do reservatório subterrâneo.
- *Variáveis independentes ou exógenas*: “Seus valores são determinados externamente ao modelo”. Pode ser valores gerados aleatoriamente ou prefixados no início de cada experimento. Exemplo: série de precipitações mensais.
- *Variáveis dependentes ou endógenas*: “São valores determinados pelo modelo a partir de outras variáveis”. Exemplo: vazões simuladas.
- *Variáveis de desempenho*: “Acumulam as observações de avaliação do comportamento do modelo em cada cenário”. Exemplo: desvios médios quadráticos entre vazões observadas e vazões simuladas.
- *Variáveis do controlador da simulação*: “Existem as do tipo relógio que registram o instante da simulação ou as do tipo lista de eventos futuros que indicam o próximo evento da simulação”. Exemplo: tamanho do passo a cada uma iteração de uma simulação.

Na existência de incertezas, o modo de obtenção dos valores das variáveis aleatórias é realizado de três maneiras (PERIN FILHO, 1995):

- a) a partir da simples análise de dados históricos diretamente, (processo demorado exige bastante memória, é inadequado nas aplicações de simulação de sistemas);
- b) a partir de histogramas construídos com dados históricos, (bastante usado na aplicação de simulação de sistemas), e
- c) a partir de distribuições clássicas cujos parâmetros foram estimados através de dados históricos, (bastante usado na utilização de simulação de sistemas).

Os *parâmetros* do modelo são valores que definem as ligações de cada rodada, caracterizando o sistema. Eles passam a ser controlados na inicialização do modelo, e a partir daí comportam-se como constantes ao longo do processo de simulação. Os modelos baseados nas representações conceituais dos processos físicos que governam o escoamento da água sobre a superfície do solo, possuem dois tipos de parâmetros:

- a) *parâmetros físicos*, que representam fisicamente as propriedades mensuráveis de uma bacia, cujas medidas podem ser realizadas a partir de mapas, Sistema de Informação Georeferenciado (SIG) e outros (p. ex., área de uma bacia ou área superficial de um curso d'água) e,
- b) *parâmetros do processo*, representam propriedades da bacia que não são mensuráveis diretamente, cuja estimativa de uma série (valores máximos ou mínimos), podem ser determinados baseados sobre julgamentos e entendimentos da hidrologia da bacia (p. ex., profundidade média ou efetiva da superfície úmida do solo).

Numa abrangência mais genérica, os modelos podem ser usados com o objetivo de descrever uma série de processos hidrológicos e usos da águas, tais como: (a) elementos de processo de escoamento (umidade do solo, precipitação, evapotranspiração, escoamento em bacia, escoamento em canal, água subterrânea); (b) elementos de qualidade da água (qualidade física, química e biológica da água); (c) modelos de recursos hídricos (abastecimento de água, controle da poluição, hidrelétricas, irrigação, controle de enchente, drenagem do solo, navegação, uso recreacional, condições ecológicas); (d) extensão de modelo (condições pontuais, domínio de bacias de planalto, domínio de canais) e, (e) modelo de base temporal (eventos simples ou períodos de previsão contínuos, previsão X predição).

Vários fatores promovem limitações nos modelos hidrológicos. Os mais frequentes são devido (a) à inadequação de caráter estrutural ou às falhas ao incorporar certos elementos teóricos; (b) limitação promovida pela falta de dados de campo apropriados à calibração e operação de modelos; (c) limitação devida à forma de se adequar a capacidade computacional; (d) limitação nos processos de calibração, e finalmente (e) aquela relacionada à aplicação de problemas de gerenciamento onde algumas restrições operacionais (por ex: restrições de caráter social, operação de reservatório multiuso) não são incorporadas nos modelos de simulação hidrológica.

A simulação consiste em “... reproduzir os aspectos essenciais de um sistema ou processo sem duplicar a natureza do propósito” (HERMANN, 1980a), ou seja, é um processo de imitar uma realidade através de modelos, em que esses modelos podem conservar (*simulação física*<sup>5</sup>) ou não (*simulação simbólica*<sup>6</sup>), as características físicas e lógicas do sistema real que está sendo imitado (SHIMIZU, 1975).

O uso da simulação de sistemas é destinado à estimativa de distribuição de variáveis aleatórias; ao teste de hipótese estatísticas; à comparação de cenários<sup>7</sup> representando diferentes soluções (políticas de operação, configuração do sistema, etc.) para o problema em estudo; na avaliação do comportamento de uma solução analítica e na avaliação de um processo de tomada de decisão em tempo real.

Existem três tipos de simuladores, os *físicos*, que representam os modelos reduzidos os quais simulam o comportamento de um protótipo; os *analógicos*, que são baseados em analogias existentes entre fenômenos hidráulicos e elétricos, e os *digitais* ou *matemáticos*, que são construídos através de programas de computador digital. O **Quadro 2.3** resume a classificação dos simuladores digitais, mais especificamente direcionado aos modelos do estudo de caso, que

---

<sup>5</sup> Processo de miniaturização ou representação parcial do sistema.

<sup>6</sup> A parte lógica do sistema real é expressa em forma de equações matemáticas, em que as variáveis representam as componentes do sistema.

<sup>7</sup> Geralmente uma solução para o problema pode representar uma configuração para o sistema ou uma política de operação do sistema. As soluções devem estar relacionadas aos cenários escolhidos.

são modelos matemáticos, com técnicas de simulação, cuja vantagem registrada é a flexibilidade e a generalidade.

*Quadro 2.3 - Classificação dos Simuladores*

* Tipos de simuladores	{ Físicos Analógicos Digitais
* Modelos matemáticos	{ Modelos analíticos Modelos com técnicas de simulação
* Modelos com técnicas de simulação	{ Simuladores de sequência hidroclimática Simuladores de sistema
* Simuladores de sistemas	{ Modelos de simulação hidrológica Modelos de simulação

O processo de simulação adotado nos modelos hidrológicos consiste basicamente das seguintes fases: escolha do modelo, seleção e análise das informações necessárias ao ajuste e verificação do modelo, calibração de seus parâmetros e validação do modelo calibrado, aplicação e estimativa das incertezas dos resultados. A metodologia proposta por DOOGE (1972), apud SINGH (1988) aplicada aos modelos de previsão possui os seguintes passos:

1. *Definir o problema;*
2. *Especificar o objetivo;*
3. *Verificar a disponibilidade dos dados;*
4. *Determinar os recursos de computação disponíveis;*
5. *Especificar as restrições econômicas e sociais;*

6. *Escolher uma classe particular de modelo hidrológico;*
7. *Selecionar um tipo particular de modelo a partir da classe dada;*
8. *Calibrar o modelo (isto é, ajustar os parâmetros);*
9. *Avaliar a performance do modelo;*
10. *Usar o modelo para a previsão proposta, e*
11. *Embutir o modelo em um modelo mais geral (ele pode ser um componente de um modelo mais geral).*

A escolha de um modelo consiste, basicamente, em se dispor de dados necessários com qualidade<sup>8</sup>; no conhecimento detalhado da região de estudo e da estrutura do modelo escolhido; da performance do processo de calibração do modelo e na aplicação do modelo à sua finalidade<sup>9</sup>, de maneira que possa descrever com certa fidelidade o sistema físico escolhido.

Durante a escolha de um modelo, apropriado à solução do problema proposto, as dificuldades que podem surgir são múltiplas. O objetivo é adequar um certo modelo ao sistema para se obter um resultado o mais próximo do sistema real. Para isso é necessário verificar se o modelo possui um número reduzido de parâmetros a serem calibrados; se as escalas temporal (horária, diária, mensal ou anual) e espacial (homogeneidade geológica e pedológica, declividade do terreno, cobertura vegetal, ocupação da bacia) são adequadas à aplicação operacional do modelo, e qual a forma de distribuição espacial da chuva (se é considerada como média ou não). Estes fatores são essenciais na escolha do modelo. Por exemplo, se o modelo for destinado à extensão de séries mensais de vazão para dimensionamento do volume útil dos reservatórios, em se tratando de modelos hidrológicos com série temporal mensal, o objetivo é obter uma série com

---

<sup>8</sup> Existe a possibilidade de ocorrer a inviabilidade de executar alguns tipos de modelos com recursos mais sofisticados, cuja metodologia solicite informações de difícil acesso ou inexistente para aquela área de estudo.

<sup>9</sup> Os modelos utilizados para a previsão em tempo real → priorizam a determinação do nível ou vazão com rapidez e precisão e; os modelos utilizados para extensão de séries hidrológicas → buscam representar bem as estatísticas da série produzida.

intervalos de tempo mensal, com precisão no período de estiagem e erros aceitáveis na distribuição dos volumes no período de cheia.

Após a definição do sistema e de suas variáveis e a escolha do modelo, é necessário estabelecer o processo para o qual os parâmetros foram selecionados - chamado de *calibração* do modelo. Para o caso dos modelos hidrológicos do tipo chuva-vazão, a calibração é um estudo de causa (chuva) e efeito (vazão). Neste processo, o sistema inicialmente busca retirar, por meio dos dados de entrada, todas as informações essenciais, com vista a avaliar os valores relativos aos parâmetros, os quais poderão induzir o modelo a produzir soluções mais próximas do sistema natural a ser modelado (RAMOS, 1989). Logo, o processo se constitui de duas partes:

- a) *especificação dos parâmetros* feita com base nas propriedades conhecidas do sistema e nos procedimentos de especificar uma estimativa inicial para os parâmetros do modelo (físicos e de processo),
- b) *estimação dos parâmetros* em que ocorre o ajustamento com relação aos dados observados das variáveis de entrada ou saída, através de várias técnicas voltadas a reduzir as incertezas na estimativa dos parâmetros de processo.

No caso de estimação dos parâmetros, que trata do processo de calibração neste trabalho, alguns critérios a respeito da amostra devem ser preestabelecidos, com base no uso do modelo, se a finalidade é a simulação de eventos curtos como enchentes ou uma estiagem ou se é para séries contínuas no tempo, onde se deseja conhecer a série de vários anos de um determinado local. No procedimento de estimativa dos parâmetros, o critério aplicado quanto à existência e à manipulação dos dados existente, é classificado em quatro métodos para a divisão da amostra a ser simulada: subdivisão da amostra teste (“*split-test*”); bacia substituta (“*Proxy basin test*”); amostra diferencial (“*differential split sample test*”) - e, bacia substituta diferencial (“*Proxy differential split sample test*”).

Definiremos a classificação a ser utilizada nos modelos usados neste trabalho, que é a Subdivisão da Amostra Teste (“*split-test*”) – **Figura 2.5**: este procedimento consiste em subdividir em duas partes a série de dados selecionada existente no local - a primeira é utilizada para o

amostra disponível é pequeno, a maior parte da série deve ser atribuída ao ajuste. Considera-se que o sistema é estacionário e os dados provenientes do posto utilizado no processo de ajuste passem a ser os mesmos dados onde ocorrerá o processo de previsão ou prognóstico.

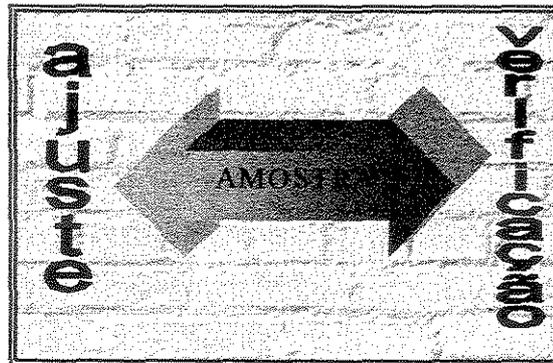


Figura 2.5 - Subdivisão da Amostra Teste

Amostra teste diferencial (“*differential split sample test*”) – Figura 2.6: este procedimento consiste em subdividir em dois períodos os dados dos postos existentes, um para o processo de ajuste do modelo, correspondente a período antecedente às alterações sofridas pela bacia, e outro posterior às alterações, que será indicado para o processo de previsão ou prognóstico. Considera-se que o sistema é não estacionário.

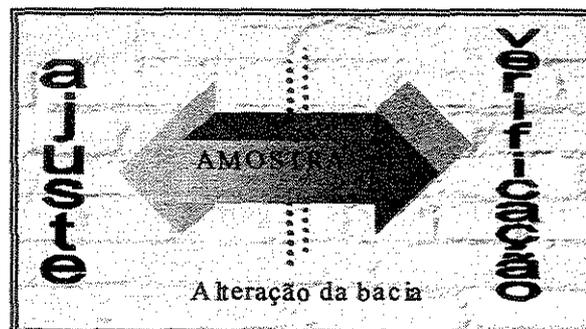


Figura 2.6 - Amostra Teste Diferencial

A estimativa dos parâmetros depende da disponibilidade de dados históricos, de medições de amostras e de determinação das características físicas da bacia. Os métodos praticados, em geral, na estimativa são:

A estimativa dos parâmetros depende da disponibilidade de dados históricos, de medições de amostras e de determinação das características físicas da bacia. Os métodos praticados, em geral, na estimativa são:

1. *medida direta* ou *estimativas sem dados históricos* - os valores dos parâmetros são baseados nas informações das características físicas da bacia (área de drenagem, comprimento da bacia medidas em campo ou mapas);
2. *ajuste por tentativa e erro (manual)* - com base nos dados observados das variáveis de entrada e saída que compõe o modelo, os parâmetros são calculados por tentativa até encontrar o melhor ajuste entre os dados observados e os calculados (funções estatísticas hidrológicas são usadas para verificar a qualidade do ajuste e verificação);
3. *amostragem* - os valores dos parâmetros são obtidos com base em medições específicas da bacia (capacidade de infiltração de um tipo de solo, condutividade hidráulica);
4. *ajuste por otimização (automática)* - são aplicadas técnicas de otimização as quais utilizam funções objetivos implícitas que relacionam diferenças entre os dados observados dos calculados pelo modelo.

As técnicas iterativas de otimização (processo de ajustamento dos parâmetros), utilizadas na calibração dos modelos neste trabalho, são as da forma *manual* e aquela que usa métodos computacionais *automáticos*. A prática vigente remete a realizar um ajuste inicial utilizando a forma automática, para, posteriormente, refinar-se a calibração dos parâmetros segundo as regras de resolução do método escolhido, levando-se em conta a experiência do analista.

A calibração manual utiliza processos subjetivos do tipo "tentativa e erro" para o ajustamento dos parâmetros. O procedimento metodológico inicia com a definição de um conjunto de parâmetros de acordo com sugestões do manual do modelo ou por valores esperados, segundo a literatura. Os parâmetros que não apresentarem grande sensibilidade devem ficar fixos. Recomenda-se até quatro parâmetros como sendo um número razoável para ser ajustado. Como início da modelagem, variar um parâmetro de cada vez até que os resultados não sofram mudanças significativas e a seguir calculando-se o valor do erro relativo. A cada ajuste de parâmetro realizado, as hidrógrafas simuladas e observadas são comparadas visualmente, para verificar-se se

as aproximações sofreram alguma melhora. O ajuste fino deve ser realizado com base em apenas dois parâmetros refinando-os com os demais.

O acompanhamento operacional do técnico habilitado e o seu conhecimento sobre a bacia, na determinação de cada parâmetro, asseguram as vantagens do método, pois a experiência é fator decisivo na interpretação dos resultados. Mas, devido ao julgamento subjetivo, o critério de parada (estabelece que o vetor de parâmetros calculado, quando aplicado ao modelo, possa produzir uma resposta próxima do sistema natural, com uma dada precisão) passa a ser uma das dificuldades - se o melhor ajuste foi obtido - portanto, diferentes usuários, de acordo com sua experiência, podem obter diferentes valores para os parâmetros em uma mesma bacia. O custo de operacionalização, devido à demanda de tempo de profissionais qualificados na simulação do modelo, passa a ser outro fator de desvantagem desta técnica.

A principal vantagem deste processo é que o hidrólogo acompanha cada passo do processo de calibração, e a desvantagem é que a técnica é extremamente trabalhosa (quanto maior o número de parâmetros a serem testados, maior o número de combinações e conseqüentemente maior o tempo de cálculo até encontrar o valor desejado).

A calibração automática dos parâmetros é um processo de cálculo matemático, o qual busca encontrar um vetor de parâmetros, através da minimização (ou maximização) de uma função objetivo e que mensura a superposição entre as séries de vazão observada e simulada. O procedimento de estimação de parâmetros pela calibração automática consiste de quatro elementos, a saber:

- a) *função objetivo*, é a expressão numérica usada para calcular a diferença entre a saída do modelo simulado e os dados observados na bacia (p. ex., soma dos desvios absolutos quadráticos, soma dos desvios quadráticos, soma dos desvios quadráticos dos picos, soma dos desvios quadráticos do logaritmo dos picos e volumes, soma dos desvios quadráticos dos logaritmo do tempo normalizado, soma das diferenças absolutas, diferenças absolutas de picos e seus tempo, diferenças absolutas de pico, dentre outras), cuja superfície descrita no espaço do parâmetro é denominada de "superfície de resposta".

- b) *algoritmo de otimização* é um procedimento lógico que é usado na busca da superfície de resposta, restringida pelos limites dos parâmetros, de tal forma que os valores destes otimizem (maximizados ou minimizados) o valor numérico da função objetivo (RAMOS, 1989 e SINGH, 1995), p. ex.,
- *método de busca local*: 1) métodos de busca direta - "método de Rosenbrock", 1960, "método da Trajetória de Busca" - Hooke e Jeeves, 1961, "método Simplex" - Nelder e Mead, 1965 e; 2) método do gradiente - "método do passo descendente"; "método de Newton" e outros;
  - *método da pesquisa global*: 1) métodos de busca aleatória - "Adaptive Random Search (ARS)" - Masri et al., 1978 e; 2) algoritmos de multiestágios e outros.
- c) *critério de parada* é usado para determinar o final da busca. A solução existe na área limitada do parâmetro onde a declividade da superfície de resposta de uma função é zero e o valor da função é mínimo. Os critérios comumente usados são:
- convergência da função - quando o algoritmo não estiver apto em melhorar o valor de uma função sobre uma ou mais interações  $\rightarrow \frac{(f_{i-1} - f_i)}{f_i} \leq \varepsilon_f$ , em que  $f_{i-1}$  e  $f_i$  são valores da função nos passos  $(i-1)$ -ésimo e  $i$ -ésimo, respectivamente, e  $\varepsilon_f$  é um valor (critério) de convergência, que pode ser igual a  $10^{-3}$ .
  - convergência do parâmetro - quando o algoritmo se mostrar incapaz de mudar os valores do parâmetro e, ao mesmo tempo, melhorar o valor da função sobre uma ou mais interações  $\rightarrow \frac{(\theta(j)_{i-1} - \theta(j)_i)}{(\theta(j)_{max} - \theta(j)_{min})} \leq \varepsilon_\theta$ , para cada  $\theta(j)$ , onde  $\theta(j)_{i-1}$  e  $\theta(j)_i$  são valores de um  $j$ -ésimo parâmetro no  $(i-1)$ -ésimo e  $i$ -ésimo passos, respectivamente, e  $\varepsilon_\theta$  é um valor (critério) de convergência, que pode ser igual a  $10^{-3}$ .
  - número de iterações máximas - o tempo de processamento computacional deve ser limitado a fim de que o algoritmo não entre em um *loop* infinito; para isto, considera-se

terminada a busca, caso um número máximo prefixado de interação não seja excedido, ou a menos que os critérios de função ou de parâmetros tenham sido alcançados.

- d) *dados de calibração* - a escolha dos dados de calibração pode reduzir algumas das dificuldades encontradas no processo. A quantidade de dados necessária e suficiente para a calibração é sugerida por SINGH (1995), sob o ponto de vista estatístico, como sendo vinte vezes o número de parâmetros a ser estimado. A qualidade dos dados depende das informações suficientes neles contidas para identificar o valor do parâmetro<sup>10</sup> - a melhor escolha recai em um conjunto de dados que contenha muitas variabilidades (informações) hidrológicas e, nos erros embutidos, tanto por medida como por registro ou outras fontes, podem deteriorar a qualidade dos dados.

Em cada passo o algoritmo calcula um novo valor para a função objetivo, executa a comparação entre o último valor calculado e prossegue seguindo em direção onde poderá encontrar um menor valor da função objetivo<sup>11</sup>. A finalização do processo ocorre quando o ponto de mínimo desta função for encontrado.

Alguns problemas são apontados devidos aos métodos de otimização: a) interdependência entre os parâmetros dos modelos - erros estão embutidos nos dados referentes às variáveis de entrada, quando não corrigidos produzem resultados distorcidos, b) descontinuidade nos algoritmos e das funções objetivo dos modelos - e, c) vários ótimos locais. TUCCI (1998) recomenda algumas medidas pertinentes à minimização deste problema no uso desta técnica:

1. os dados de entrada deverão ser avaliados com a finalidade de se identificar possíveis erros embutidos que possam gerar resultados tendenciosos durante o processo de ajuste e verificação do modelo;

---

<sup>10</sup> Dado selecionado num período seco, determinado processo de escoamento pode não ser ativado, a resposta do modelo seria insensível para algum parâmetro que determine a separação da umidade entre vários componentes dos escoamentos subsuperficial e superficial.

<sup>11</sup> Apesar de alguns autores afirmarem que a escolha da função objetivo é um processo subjetivo, esta escolha deve ser compatível com a deliberação da aplicação do modelo. DISKIN e SIMON (1977) e CANEDO (1979), apud RAMOS (1989), através de seus estudos sobre critérios para a escolha da função objetivo, afirmam que se a escolha for feita de maneira inadequada, as incertezas sobre os resultados serão aumentadas.

2. o intervalo potencial de variação dos parâmetros deve estar bem definido;
3. utilização de técnicas tradicionais de otimização e por fim efetuar a verificação de possível coerência dos resultados;
4. os resultados finais serão analisados à luz da melhor solução hidrológica referentes aos objetivos propostos, independentemente das verificações estatísticas e da otimização dos parâmetros.

Dentre as vantagens que o método possui, destacam-se a velocidade de processamento; conforto e menor subjetividade na fase de calibração; facilidade no trabalho e diminuição da subjetividade do processo manual. Como desvantagens, estão relacionados os aspectos da precisão e a confiabilidade da técnica, e a falta de acompanhamento do hidrólogo na calibração passo a passo dos parâmetros.

A próxima tarefa corresponde à fase de *validação* ou *verificação* do modelo, a qual é essencial para mostrar se resiste a qualquer aplicabilidade. A proposta é observar qualquer influência que possa ter sido exercida até os parâmetros estimados devido a imperfeições existentes no procedimento de calibração. A validação consiste em dividir em duas partes a série dos registros hidrometeorológicos disponíveis: a primeira parte é usada no processo de calibração e a segunda na validação. Esta fase deve contemplar uma minuciosa verificação visual da aderência entre as séries de vazões observadas e as simuladas, bem como uma análise dos valores correspondentes às variáveis de estados dos reservatórios, os componentes da vazão total, da tendência (caso haja) do escoamento básico e, finalmente, do balanço de massa.

Outra fase existente no julgamento da performance de um modelo hidrológico é a *análise de sensibilidade* que a função-resposta de uma bacia a uma entrada,  $Q(t)$ <sup>12</sup> tem com relação às variações de todos os parâmetros estimados - que parâmetro pode ser considerado bem determinado (sensível) e qual parâmetro é pouco determinado (insensível)<sup>13</sup>. A importância da

---

<sup>12</sup>  $Q(t) = S[P(x,t), E(x,t), \theta_i] + e_t$ . Sendo que  $S[.]$  representa o modelo hidrológico;  $P(x,t)$  a matriz de precipitação;  $E(x,t)$  a matriz de Evaporação potencial;  $x$  e  $t$  representam o espaço e o tempo;  $\theta_i$ , para  $i=1, \dots, n$ , são parâmetros do modelo e,  $e_t$  é o vetor do erro de estimativa do modelo com relação ao valor real.

<sup>13</sup> Considerando que as variáveis de entrada são as mesmas, a variável de saída é dependente dos parâmetros →

análise se traduz, principalmente, na determinação dos valores das restrições que são impostos aos parâmetros, no momento da inicialização da fase de calibração, como também conhecer a sensibilidade que a função objetivo utilizada no ajuste dos parâmetros do modelo, a qual determina o grau de medida de aproximação dos dados estimados aos dados observados.

O procedimento inicial requer a obtenção de uma "região de indiferença"<sup>14</sup> para os parâmetros estimados - região entorno do melhor parâmetro estimado. A análise desta região, pode determinar a existência de grande interdependência entre dois ou mais parâmetros que, por sua vez, pode assinalar sobreparametização ou fraca formulação estrutural do modelo e até inadequação do conjunto de dados de calibração. Quanto maior a sensibilidade de um modelo responder a um parâmetro, em geral, mais breve o parâmetro será otimizado, ou seja, parâmetros insensíveis freqüentemente não alcançam seus valores verdadeiros, isto implica dizer que devemos incluir na otimização apenas os parâmetros que sejam suficientemente sensíveis.

A análise é dividida em sensibilidade dos parâmetros e sensibilidade dos componentes (SINGH, 1988):

- a) *sensibilidade dos parâmetros*: as mudanças ocorridas por um ou mais parâmetros alteram o resultado da solução  $S = f(\theta_1, \theta_2, \dots, \theta_n)$ , para  $i=1,2,\dots,n$ . Em se tratando de uma definição mais generalizada da sensibilidade  $s$ , ela pode ser calculada através da expressão

$$s = \frac{\partial S}{\partial \theta_i} \quad (2.3)$$

e  $s$  pode ser determinada por diferenciação direta ou por métodos de perturbações. Alguns métodos de otimização para calibração de modelos promovem análise de sensibilidade; tais métodos mais usados em hidrologia são: Método de *steepest-descent*, Cauchy (1847);

$$dQ = \frac{\partial S}{\partial \theta_1} d\theta_1 + \frac{\partial S}{\partial \theta_2} d\theta_2 + \dots + \frac{\partial S}{\partial \theta_n} d\theta_n$$

<sup>14</sup> Métodos para obtenção desta região não estão bem desenvolvidos. As análises são conduzidas usando aproximações quadráticas para uma superfície de resposta na região de um melhor valor para o parâmetro  $\theta^*$ , usando expansão de séries de Taylor, para a segunda ordem, de uma função objetivo  $F(\theta)$  (SINGH, 1995).

Método de *patter-search*, Green (1970); Método de DeCoursey-Snyder, DeCoursey e Snyder (1969) e Método de Rosenbrock, Rosenbrock (1960).

- b) *sensibilidade dos componentes*: mede o efeito da variação na entrada da função I sobre a saída da função S. Pode, também, ser usada para identificar uma importância relativa de subsistemas individuais dentro do sistema,

$$s = \frac{\partial S}{\partial I} = \frac{\Delta S}{\Delta I} \quad (2.4)$$

A *análise de erros* é outro procedimento existente na simulação de modelos hidrológicos. Trata dos efeitos dos erros resultantes, originados de diversas fontes, na solução (*output*) do modelo. SINGH (1988) identificou quatro fontes de erros:

- a) modelos matemáticos são aproximações idealizadas de sistemas físicos;
- b) parâmetros de modelo são estimados a partir de dados históricos e experimentais, estando sujeitos a erros de dados e de estimação;
- c) soluções do modelo ocasionam erros de truncamento devido à necessidade de usar grande número de operações matemáticas, e
- d) procedimentos computacionais produzem erros de arredondamento na execução de operações elementares.

Os erros resultantes a partir dessas fontes, classificam-se em *erros randômicos* (*aleatórios*) e *erros sistemáticos*. Os primeiros ocorrem quando o modelo não demonstra tendência alguma a superestimar ou subestimar resultados para um número sucessivo de intervalos de tempos. Os *erros sistemáticos* ocorrem quando um erro tende a persistir sobre uma série de intervalos de tempo sem mudanças de seu sinal (erros sistemáticos em dados irão refletir em valores de parâmetros incorretos).

Ainda com relação ao ajuste dos modelos hidrológicos, são realizadas algumas estatísticas adicionais aos resultados obtidos, tanto no processo de calibração, como no processo de validação dos modelos, tais como: a) erro padrão de estimativa (*Root-mean-square error*,

RMSE); b) erro percentagem de volume (*Percent volume error, %VE*); c) erro percentual da vazão máxima (*Percent error of maximum flow, %MF*), dentre outras.

Em resumo, de acordo com os objetivos do modelo, o ajuste será verificado com base em: a) valores observados e calculados das seguintes funções: hidrogramas mensais; curva de permanência, e outras; b) verificação estatística dos ajustes.

E, finalmente, a apresentação dos resultados requer alguns cuidados quanto ao modo de apresentação. As formas habituais usadas são três: simples apresentação de resumo dos dados; apresentação em tempo real do comportamento do modelo e apresentação de um comportamento já registrado anteriormente, permitindo visualizar a simulação.

### 2.3.2 *Incertezas dos Resultados da Simulação*

As incertezas geradas pelos resultados dos modelos decorrem do agrupamento de várias fontes distintas, mesmo em se tratando de modelos exaustivamente testados.

As principais incertezas verificadas na análise dos resultados de um modelo são as variações aleatórias e erros de medição das variáveis de entrada e de saída dos resultados; as limitações existentes na estrutura dos modelos quando da representação do sistema e simplificação dos processos envolvidos e as incertezas devido às estimativas dos parâmetros. As fontes de incerteza são apresentadas no **Quadro 2.4**.

**Quadro 2.4 - Principais Fontes de Incerteza na Simulação de Vazões com Uso de Modelos Chuva-Vazão**

<i>Fontes de Incertezas</i>	
<b>Registros de Dados Hidrometeorológicos da Bacia Hidrográfica</b>	<ul style="list-style-type: none"> <li>• Erros na coleta dos dados hidrometeorológicos.</li> <li>• Redução de dados pontuais em médias espaciais.</li> <li>• Redução de dados contínuos em médias temporais.</li> <li>• Erros no processo indireto de estimação de dados de vazão.</li> </ul>
<b>Estrutura dos Modelos Chuva-Vazão</b>	<ul style="list-style-type: none"> <li>• Conhecimento imperfeito dos processos físicos.</li> <li>• Aproximações para que representações desses processos sejam tratadas de forma viável.</li> <li>• Tratamento de variáveis com variação espacial de forma concentrada.</li> <li>• Tratamento seqüencial de processos concomitantes.</li> <li>• Omissão de processos considerados menos relevantes.</li> </ul>
<b>Calibração de Modelos Chuva-Vazão</b>	<ul style="list-style-type: none"> <li>• Subjetividade do processo tentativa e erro.</li> <li>• Escolha da função objetivo.</li> <li>• Critério de convergência na otimização.</li> <li>• Ocorrência de mínimos locais.</li> <li>• Tamanho das séries de dados de calibração.</li> </ul>

Fonte: O'DONNELL e CANEDO (1980), apud RAMOS (1989)

Dentre as formas de avaliar a performance (analisar a adequabilidade, a confiabilidade e o uso) da técnica determinística de modelação de sistema hídrico, recomenda-se identificar, isolar e quantificar as fontes de incerteza e seus efeitos.

O desempenho dos modelos de simulação está relacionado de maneira direta à qualidade dos dados empregados, já comentados anteriormente. Em se tratando dos dados referentes às características físicas da bacia, a ausência de dados pode ser solucionada através de campanha de campo, onde se poderá extrair essas informações em tempo, provavelmente, hábil. Já para o caso de dados hidrometeorológico, isto se torna um pouco difícil, ou seja, torna-se bastante limitante fazendo com que os modelos se adequem.

Na década passada, as incertezas atribuídas às estruturas dos modelos, em muitos casos eram atribuídas a problemas de disponibilidade de hardware computacional, hoje prontamente superada através dos computadores de última geração. A complexidade existente no fenômeno do ciclo hidrológico dificulta a representação matemática de todo seu processo e nem sempre é possível obter informações de campo. Isto leva alguns modelos a requererem algum tipo de simplificação de sua estrutura, eliminando um ou mais fenômeno do ciclo. Diante das simplificações, é relevante a atenção na escolha do modelo, pois a sua estrutura deve ser compatível com a utilização operacional do modelo.

As maiores atenções devem estar voltadas para a parte do modelo que trata da descrição do solo, pois

*“... as técnicas usadas para descrever a infiltração e a percolação no solo são ainda insatisfatórias quando comparadas com aquelas que descrevem outros fenômenos físicos” e ainda “... é aconselhável que os parâmetros tenham forte significado físico e sejam, de preferência, passíveis de medição direta”*  
RAMOS (1989),

Algumas incertezas provenientes da fase de calibração dos modelos, listadas no **Quadro 2.5**, podem ocorrer tanto na *calibração manual* (tentativa-e-erro) ou na *calibração automática* dos parâmetros.

## 2.4 Modelos de Gerenciamento de Recursos Hídricos

Os modelos usados como ferramenta fundamental no auxílio do gerenciamento de recursos hídricos são necessários como meio de quantificação dos fenômenos que constituem o sistema, permitindo, assim, avaliar as diversas alternativas propostas no planejamento dos recursos hídricos, promovendo a melhor qualidade no processo de decisão.

Dentre os vários tipos de modelos matemáticos existentes são particularmente tratados a seguir, os modelos hidrológicos do tipo chuva-vazão, cuja técnica matemática e estatística (métodos numéricos, otimização e estatística) aplicada, é a de otimização dos parâmetros escolhidos na representação do sistema em estudo e restringindo àqueles com características determinísticas e conceituais.

### 2.4.1 *Modelos de Simulação Chuva-Vazão*

Os modelos chuva-vazão (MCV) são instrumentos de simulação hidrológica, isto é, dada uma série de registros de precipitação e um conjunto de parâmetros associados, permitem gerar séries de vazão com intervalos de discretização de tempo horário, diário, mensal, dentre outros.

Os objetivos da utilização dos MCV na área de recursos hídricos são entender o comportamento dos fenômenos hidrológicos da bacia; analisar a consistência da curva-chave; preenchimento de falhas; dimensionamento de obras hidráulicas; na previsão de cheias e efeitos resultantes da modificação do uso da terra.

A característica destes modelos é representar o ciclo hidrológico como uma seqüência de processos de transferência e de armazenamento de água entre reservatórios hipotéticos, associados às camadas de solo (CIRILO e LUCENA, 1992).

O melhor modelo a ser selecionado está intrinsecamente relacionado ao erro dos resultados da simulação, a partir da finalidade a que o modelo se destina. HERMANN (1980, b) estabelece dois pontos de vista com relação à escolha,

- Do ponto de vista do hidrólogo: “...é aquele que mais detalhadamente representa esses fenômenos”.
- Do ponto de vista do engenheiro: “...é aquele que resulta num compromisso entre o custo de sua exploração e a precisão dos resultados fornecido”.

Para que a performance dos Modelos Chuva-Vazão (MCV) seja alcançada, visando aos objetivos estabelecidos, alguns fatores devem ser cuidadosamente considerados, tais como,

- a) *objetivo predominantes dos resultados*; (p. ex.: obtenção do hidrograma de projeto, implica que a concordância entre as vazões simuladas e observadas no período de enchentes deve ser bem ajustada; série de vazões para dimensionamento de volume de reservatório, implica que a distribuição dos volumes anuais possua um erro reduzido, a representação dos períodos de estiagem (críticos) sejam bem definida e para os períodos chuvosos possua uma distribuição de vazões médias não tendenciosa) e;
- b) *dados disponíveis*; no caso da inexistência de dados de vazão para o ajuste dos parâmetros, é recomendado procurar uma bacia próxima a de estudo, a qual possua características semelhantes (cobertura vegetal, declividade média, climatologia, solo e formação geológica), para que se possa fazer a transposição dos parâmetros.

A estrutura dos MCV, segundo TUCCI, (1998), consiste em cinco elementos distintos: discretização da bacia, variáveis de entrada, estrutura básica da integração dos processos, aquisição dos dados físicos das bacias e determinação dos parâmetros.

A discretização da bacia é realizada com base nas seguintes estruturas: a) área de drenagem do curso d'água da bacia ou da subdivisão desta em sub-bacias, constituindo-se, assim, de uma estrutura do tipo *distribuída por bacia* ou *sub-bacias*, cuja divisão está relacionada à disponibilidade de dados, locais de interesse e variabilidade de parâmetros físicos da bacia; b) a

área de drenagem da bacia é discretizada por formas geométricas, em que o detalhamento dos processos torna-se bem maior que na estrutura anterior - *distribuída por módulos* e; c) em toda a área da bacia considera-se uma precipitação média, assim como as variáveis referentes aos processos hidrológicos são consideradas concentradas no espaço - estrutura *concentrada*.

De modo geral, as variáveis de entrada para este tipo de modelo são a precipitação e a evapotranspiração potencial. Os dados necessários à construção de MCV, além das variáveis de entrada são a vazão no intervalo de tempo escolhido; evaporação, e características físicas da bacia (área, taxa de áreas impermeáveis, declividade média da bacia e do rio, tipo de cobertura vegetal, características médias do solo e formação geológica, entre outros) (TUCCI, 1987).

Os MCV têm como estrutura básica da integração dos processos hidrológicos procurar descrever os vários percursos da água pela superfície e pelo interior do solo, simulando, desta forma, o balanço vertical dos fluxos e o escoamento na sub-bacia, o que chamamos de *fase terrestre ou bacia* (ex. modelo SMAP, LOPES et al. (1981) e o modelo apresentado pelo *Soil Conservation Service* (1975)) e, através das calhas fluviais, por meio de simulação da propagação das vazões de montantes dos rios e canais e das contribuições das bacias, chamados de *fase canal* (ex: modelo STANFORD IV que apresenta duas estruturas, fase bacia e fase canal, criado por CRAWFORD e LINSLEY (1966) e o modelo SSARR (*Stramflow and Reservoir Regulation*) desenvolvido pelo *US Army Corps of Engineers* (1972) que apresenta, além das duas fases, um terceiro módulo que trata da regularização de reservatórios).

A recente revolução na tecnologia dos sistemas de informação e comunicação tem favorecido tanto na estrutura dos modelos de hidrológicos como também na aquisição dos dados que o compõe. Exemplos incluem tecnologias por satélite e sensoriamento remoto - aquisição de dados em áreas inacessíveis; GIS (*Geografic Information Systems*) - gerenciamento de dados, tais como realimentação de dados, manipulação e organização; inteligência artificial permite realizar modelos de bacias que possam ser operados mesmo por pessoa que não sejam hidrólogos, e análises de risco e confiabilidade que providencia informações sobre precisão dos resultados do modelo que um usuário queira saber a respeito.

Vários são os modelos que determinam seus parâmetros através de métodos de ajuste manuais ou por otimização bem como por estimativas.

Devido à existência de um grande número de MCV (**Quadro 2.5**), amplamente usados no gerenciamento de recursos hídrico, optou-se em escolher dois modelos, um com características determinísticas conceituais não-lineares (modelos SMAP) e outro determinístico caixa-preta não-linear (modelo RNA) e que, através de seus resultados, possam atender aos objetivos usuais na área de gestão e planejamento de bacias hidrográficas; projetos hidrológicos de construção e operação de reservatórios, projetos de irrigação ou drenagem artificial, estudos de cheias ou secas, dentre outros.

**Quadro 2.5 - Modelos Hidrológicos dos Tipos Caixa-Preta e Conceitual**

<i>Modelos Hidrológicos</i>		
<i>Caixa-Preta</i>		
Linear	Tempo Contínuo	Método Racional, Método do hidrograma unitário e Métodos de tempo-área
Linear	Tempo Discreto	Método do único evento; Método de Collins; Método de substituição anterior; Método de aproximação sucessiva; Método steepest descent; Método Houserholder
Não-Linear		Método de Brandstetter-Amorocho, 1970; Método de Harder-Zand, 1969; Método de Papazafiriou, 1973; Método de Kuchment-Borschevsky, 1971; Método de Diskin-Boneh, 1972
<i>Conceitual</i>		
Linear	Tempo Contínuo	Modelo de Zoch, 1934; Modelo de Clark, 1945; Modelo de O'Kelly, 1955; Método para canal linear e reservatório linear em séries, Método para canais lineares em cascata proposto por Mathur, 1972; Modelo de Nash, 1957; Modelo em cascata de reservatórios lineares desiguais; Modelo de Dooge, 1959.
Linear	Tempo Discreto	Modelo de Nash para tempo discreto; Modelo de Chow-Kulundawamy, 1971; Modelo de Dingman, 1983
Não-Linear	Tempo Contínuo	Método de Muskingum Generalizado, Ding, 1967; Método de Chen-Singh, 1976; Dooge, 1967; Buanpeng e V.P.Singh, 1977;
Não-Linear	Tempo Discreto	Chiu e Huang, 1970

Fonte: SINGH, 1988.

### 2.4.1.1 Modelo Determinístico Conceitual Chuva-Vazão

A simulação simbólica, descrita em termos analíticos, possui uma grande complexidade de cálculo devido às equações que representam o sistema (p. ex., a descrição dos fluxos da fase terrestre dos processos hidrológicos pelas equações de Navier-Stocks). Portanto, grande parte das simulações tem recorrido com o uso do computador com equações mais simples e segmentação da bacia, para obter-se resultados mais rápidos e precisos.

O uso da simulação na engenharia possui um grande desempenho na área do planejamento de recursos hídricos, ao se projetar ou avaliar um sistema complexo, como, por exemplo, previsão de cheia em uma bacia hidrográfica, onde é realizado um modelo de chuva-vazão e, partir da validação deste, os valores da vazão decorrentes das chuvas para um período futuro são projetadas, ou em estudos de sistemas hídricos com geração e distribuição de água em que se objetiva o melhor aproveitamento da água.

Classificação da simulação simbólica (ou simulação) é apresentada em tipos: *simulação de problemas determinísticos* e *simulação de problemas estocástico ou probabilísticos*<sup>15</sup>. Simulação de problemas determinísticos “*refere-se à resolução desses tipos de problemas, tais como, equações diferenciais, integrais, matrizes, etc., através de processos experimentais em computadores*” (SHIMIZU, 1975).

Os modelos<sup>16</sup> não-lineares, que utilizam a chuva total para o cálculo de hidrograma, tendem a equacionar os processos de interceptação vegetal, detenção superficial, infiltração, evaporação e percolação no meio poroso, visando à estimativa do hidrograma total.

A grande aplicação destes modelos hidrológicos na área dos recursos hídricos é justificada pela inclusão de todo ou parte do ciclo hidrológico no seu equacionamento. Para

---

<sup>15</sup> Simulação de problemas estocásticos “... *abrange os casos mais comuns e importantes da simulação, pois tais problemas (englobam os de estatística e os de pesquisa operacional: problemas de estoque, filas, planejamento e de competição) ... não podem ser resolvidos através de métodos matemáticos usuais e a simulação é o melhor ou muitas vezes o único método de resolução*” (SHIMIZU, 1975).

<sup>16</sup> “*É um sistema imperfeito e simplificado criado para representar um sistema complexo*”.

RAMOS (1989), a vantagem que estes modelos exercem sobre os modelos lineares, os quais fazem análises hidrológicas considerando alguns eventos chuvosos separadamente, é que aqueles “... podem analisar uma longa série temporal, procurando interpretar melhor as não-linearidades contidas nos processos ligados à bacia hidrográfica, propriamente dita, e a calha fluvial de forma conjugada”.

A partir da segunda metade deste século, foi introduzida uma nova técnica de modelagem do comportamento das bacias hidrográficas, a qual tem como base conceitual o ciclo hidrológico. Os modelos que utilizam desta técnica são chamados de *Modelos Conceituais Chuva-Vazão*.

Os modelos conceituais possuem “... uma expressão matemática das complexas interrelações entre os vários fenômenos físicos que compõem o ciclo hidrológico, permitindo, para uma dada região, um conhecimento mais claro do movimento da água sob o ponto de vista hidrológico” (RAMOS, 1989) e, geralmente, consideram as leis físicas (modelos chuva-vazão baseados em formas espacialmente uniformes da equação da continuidade e a relação armazenagem-descarga). Estes modelos apresentam bons resultados com relação à eficiência e economia para alguns tipos de problemas.

Os modelos conceituais chuva-vazão caracterizam-se por reproduzirem condições médias na bacia hidrográfica, cujo objetivo central é a qualidade do hidrograma de saída. Os processos a serem simulados são a continuidade do volume e o armazenamento. Vários parâmetros compõem o modelo, sendo eles baseados em formulações empíricas e variáveis que serão avaliadas, segundo seus valores médios e calculados em intervalos de tempo discretizados.

## CAPÍTULO III

# REDES NEURAIIS ARTIFICIAIS

### 3.1 Introdução

Inicialmente, o objetivo dos modelos de RNA's eram reproduzir o mais próximo possível os mecanismos do cérebro humanos, levando-se em conta os procedimentos de tomar decisões, processar, aprender, lembrar e otimizar as informações. Mas as pesquisas até aqui desenvolvidas, ainda prosseguem nos aperfeiçoamentos da técnica, sem ter alcançado a similaridade do método com a anatomia do cérebro humano.

Neste sentido, as redes são treinadas a partir do reconhecimento de exemplos, tal como o ser humano aprende a reconhecer um curso d'água a partir de um exemplo de um rio que lhe foi ensinado. As redes também tem a capacidade de generalização após o treinamento, por exemplo, de uma série temporal hidrológica (vazões) como dados de entrada.

Define-se RNA como sendo um circuito composto de um grande número de elementos de processamento simples, que não estão baseados na estrutura neural. Cada elemento opera

somente sob uma informação local (NIGRINI, 1992). ZURADA (1992) simplifica a conceituação afirmando que o sistema neural ou RNA, são sistema celulares físicos os quais podem adquirir, armazenar e utilizar conhecimentos experimentais. Em outras palavras, RNA's são unidades de processamento numérico, cuja arquitetura em camada produz um fluxo de informações com ou sem realimentação, possuindo uma estrutura de processamento de sinais com grande poder de adaptação e capacidade de representação não linear.

São representadas por unidades interconectadas através de processamentos não lineares estáticos, onde a(s) entrada(s) na rede são vetores e sua respectiva(s) saída(s) são escalares, chamadas de neurônios artificiais. Apresentam grande competitividade com os métodos lineares, quando este não apresentam bom desempenho nos processos que, particularmente, envolvem aproximação de funções multivariáveis, identificação e controle de sistema dinâmicos. As redes além de calcular qualquer função computável, estão habilitadas a resolverem problemas de classificação e mapeamento e aproximação de funções.

A eficácia das RNA's com relação à aplicação nos modelos hidrológicos do tipo conceitual, é constatada devido a redução da participação do usuário (comumente não especializado) em seu desenvolvimento, bem como, na capacidade que ela possui na determinação automática da solução de problema de ordem complexa, tratada nesse tipo de simulação hidrológica.

Nas últimas décadas foram grandes os investimentos voltados a pesquisa e aplicações de RNA's nas mais diversas áreas do conhecimento. Na agricultura, por exemplo, DECK et al (1995) compararam RNA com uma máquina tradicional classificadora por inspeção visual e, TAO et al (1995) aplicaram RNA na inspeção visual das cores de tomate e batata para um processo seletivo. Nas ciências econômicas (TRIPP e TURDAN, 1993) e indústria (TAWEL, MARKO e FELDKAMP, 1998) diversos são os investimentos em busca de novas tecnologias aplicadas. Outras áreas das ciências estão em grande fase de aprimoramento da aplicação de RNA: eletrônica, aviação, automobilística, medicina, robótica, telecomunicações, linguagem, segurança, entre outras.

Com o objetivo de posicionar o método de otimização aplicado ao algoritmo de simulação em modelos conceituais do tipo chuva-vazão, é apresentada uma síntese sobre os modelos de otimização enfatizando-se as categorias usualmente utilizadas, seja na calibração automática de modelos chuva-vazão tradicionais como, também, na modelagem proposta por RNA.

Em seguida, são descritos os fundamentos de RNA's de maneira a direcionar a compreensão do processo de aprendizagem a ser utilizado no tipo de configuração de rede escolhida para simular os diferentes cenários do sistema proposto.

## 3.2 Otimização de Sistemas

São apresentados alguns fundamentos de otimização não linear através de definições de conceitos básicos sobre o modelo de otimização, bem como algumas análises serão desenvolvidas com relação à solução do modelo, direcionado para o caso de problemas com restrição e, particularmente, sem restrição, o qual constituiu o tipo de otimização do modelo proposto.

### 3.2.1 Métodos de Otimização

Dentre os vários métodos de otimização existentes, será feita uma breve descrição daqueles que serão aplicados aos modelos em estudo.

Na classificação mais usual dos métodos de otimização global, é comum encontrarmos sua divisão segundo o aspecto determinístico ou estocásticos de solução. Dentre as possíveis classificações, distingue-se as categorias dos *métodos indiretos* e *métodos diretos de otimização*. Os *métodos indiretos* são aqueles que dependem da

“... comparação direta dos valores numéricos assumidos em dois ou mais pontos, ou seja, fazem uso de condições necessárias para que um ponto seja mínimo ou máximo, expressos em relação numérica.” (NOVAES, 1978).

Os métodos indiretos não serão objeto de estudo deste trabalho, porém, os *métodos diretos* são descritos de forma resumida mais a diante.

KAN e TIMMER (1989) propõem uma nova abordagem na classificação destes métodos, baseados sob o que eles denominam de “*fundamentos filosóficos de um método*”:

- a) *Divisão e Busca*: neste tipo o conjunto  $S$  viável é dividido sucessivamente em pequenas sub-regiões  $S_\alpha$ , entre as quais o mínimo global é procurado. A abordagem natural dos problemas de otimização global é conduzida através de uma generalização apropriada dos métodos *branch and bound*, uma técnica de solução que é conhecida na área de otimização combinatorial.
- b) *Aproximação e Busca*: nesta abordagem a função  $f$  é substituída por uma melhor função de aproximação de crescimento  $\tilde{f}$  com o cálculo facilitado a partir de interações computacionais.
- c) *Decréscimo Global*: este método visa um melhoramento permanente nos valores de  $f$ , culminando com determinação do mínimo global.
- d) *Melhoria do Mínimo Local*. explorando a disponibilidade de uma rotina de busca local eficiente este método procura garantir a seqüência do mínimo local do valor decrescente. O mínimo global será pelo menos um resultado desta seqüência calculada.
- e) *Enumeração do Mínimo Local*: é realizada uma completa enumeração de mínimos locais ou de um subconjunto destes, e, com isso, a solução para resolver os problemas de mínimo global é encontrada.

Neste estudo, nos deteremos a técnica de otimização do *decréscimo global*.

Um modelo de otimização constitui-se de uma função objetivo  $f(x_1, x_2, \dots, x_n)$  a qual se deseja maximizar ou minimizar, na qual as *variáveis de decisão* do problema correspondem a  $x_1, x_2, \dots, x_n$ , cujos valores ótimos se busca determinar. Pertencem também ao modelo, as *funções de restrição* (igualdade ou desigualdade)  $g_i(x_1, x_2, \dots, x_n)$ , para  $i=1, 2, \dots, n$ , a qual delimita a *região factível*<sup>1</sup> das *variáveis de decisão* ou região de domínio do problema. Ao conjunto ainda fazem parte os parâmetros do modelo, representados por  $b_i$ , em que  $i=1, 2, \dots, m$ . A representação do problema é feita pela seguinte expressão;

$$\text{Max (ou Min) } f(x_1, x_2, \dots, x_n) \quad (3.1)$$

sujeito a

$$\begin{aligned} g_1(x_1, x_2, \dots, x_n) &> b_1; \\ g_2(x_1, x_2, \dots, x_n) &> b_2; \\ &\dots\dots\dots \\ g_m(x_1, x_2, \dots, x_n) &> b_m \end{aligned} \quad (3.2)$$

O conjunto  $(x_1, x_2, \dots, x_n)$  de soluções satisfaz a equação (3.2) e por isso é chamado de solução factível. Dentre estas soluções aquela que satisfaz (3.1) é chamada de solução ótima.

Uma função  $f(x)$  definida sobre um conjunto testado  $\Omega$  em  $R^n$  é dita obter um *mínimo global ou absoluto* sobre  $\Omega$  no ponto  $x^*$ , se  $f(x) \geq f(x^*)$  para todo ponto  $x \in \Omega$ . Se  $f(x)$  for definida em todos os pontos na vizinhança  $\delta$  de  $x^*$  em  $R^n$ , a função é dita ter um *mínimo local ou relativo* em  $x^*$ , se existir um  $\varepsilon$ ,  $0 < \varepsilon < \delta$ , tal que, para todo  $x$ ,  $0 \leq \|x - x^*\| < \varepsilon$ ,  $f(x) > f(x^*)$ .

A elaboração de um modelo de otimização implica na análise detalhada do processo em estudo, facilitando eventuais ajustes nos casos em que a integração de dois ou mais subsistemas solicitem uma otimização global. Então, um problema de otimização global requer estabelecer um

<sup>1</sup> Região do espaço a qual é limitada pelas restrições impostas pelo problema.

algoritmo que, sem restrições, encontre o *ótimo global* (um mínimo ou máximo global),  $x^*$ , de uma função objetivo. Existem diversos problemas de natureza global, dentre eles, problemas de modelos técnicos e aplicações econômicas, nas quais funções custo multimodais devem ser minimizadas.

Inicialmente deve ser traçada a formulação do problema, guardando a devida relação com a configuração física e condições operacionais. Caso o problema esteja mal formulado, implica em resultados de otimização errôneos ou insignificantes para a solução do problema. O segundo passo é definir os limites físicos e operacionais, objetivando representar da melhor maneira possível a situação real em estudo. Finalmente dentre as técnicas disponíveis, define-se o modelo matemático adequado com vistas à otimização desejada. Em seguida, passa-se a interpretação dos resultados com eventuais ajustes nas equações ou em seus parâmetros (coeficientes), ou ainda nos limites pré-especificados. Formatado o problema e a técnica, pode-se ainda proceder à análise de sensibilidade.

### 3.2.1.1 Métodos Diretos

Os *métodos diretos* são assim chamados por serem, geralmente, procedimentos iterativos numéricos ou algoritmo, cujas formulações matemáticas dos processos físicos simulados, geralmente são compostas por expressões não lineares. Esses métodos operam diretamente sobre a função objetivo, para a obtenção de respostas numéricas e exigem a determinação e equiparação dos valores da função a otimizar, em vários pontos localizados dentro da região de definição das variáveis independentes. LOPES e PORTO (1991) alertam sobre a subjetividade da escolha da função objetivo como uma das críticas ao método. Também acrescentam o fato de que, esses métodos podem convergir a um mínimo local da função objetivo, sem ter passado ao ponto mínimo global.

Estes problemas que empregam técnicas de otimização utilizam recursos de Programação Não Linear (PNL) e apresentam dois tipos de soluções de problemas de otimização de funções,

aqueles com restrições e os sem restrições. A classificação dos métodos que empregam PNL (CIRILO,1997), é dividida segundo a técnica utilizada, ou seja, dividem-se em *métodos com técnicas analíticas*<sup>2</sup>, as quais procuram determinar as soluções ótimas através de sistemas de equações com o auxílio de derivadas e, as *técnicas de busca numérica*, as quais usam informações precedentes, através de procedimentos iterativos, na busca de melhores soluções durante o processo de otimização .HILLIER (1995) classifica os métodos de solução dos problemas de PNL em otimização irrestrita, otimização linearmente restrita, programação quadrática, programação convexa, programação superável, programação não-convexa, programação geométrica e programação fracional. Neste estudo será aplicada a técnica de otimização irrestrita multivariável.

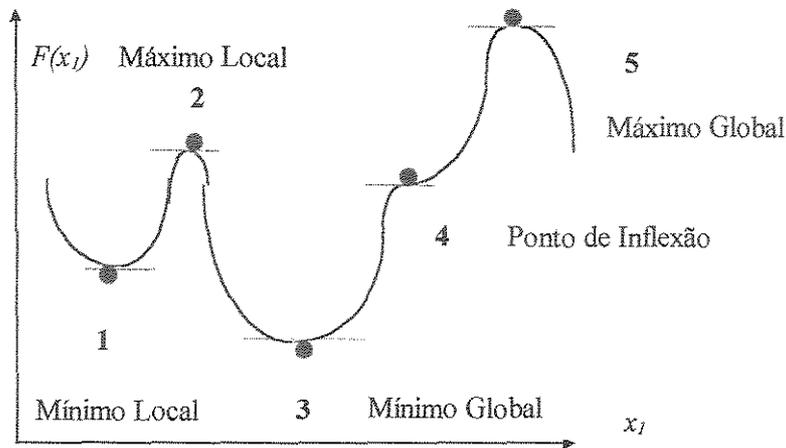
Os problemas de PNL apesar das incertezas - em muitos casos quando a solução ótima for a melhor encontrada dentre as possíveis soluções - na limitação quanto ao tempo de operação das informações, hoje em dia são praticamente vencidos com a capacidade e com a velocidade de processamento dos computadores digitais. Mas grande vantagem recai no alcance do modelo quando calibrado para um determinado sistema, este normalmente dispensar modificações em sua formulação, aumentando a precisão dos dados a serem calculados.

Grande parte dos *métodos de busca direta sem restrições* aplica-se apenas às funções unimodais, as quais apresentam um ponto extremo dentro desse intervalo de definição. Caso as funções indiquem mais de um ponto extremo são ditas plurimodais - **Figura 3.1**, BRAGA (1987).

Os *métodos diretos* consomem tempo computacional relativamente longo para resolverem problemas de otimização complexos. Embora não forneçam com precisão o ponto ótimo existem alguns processos de otimização direta que permitem avaliar o intervalo de precisão do resultado (NOVAES, 1978).

---

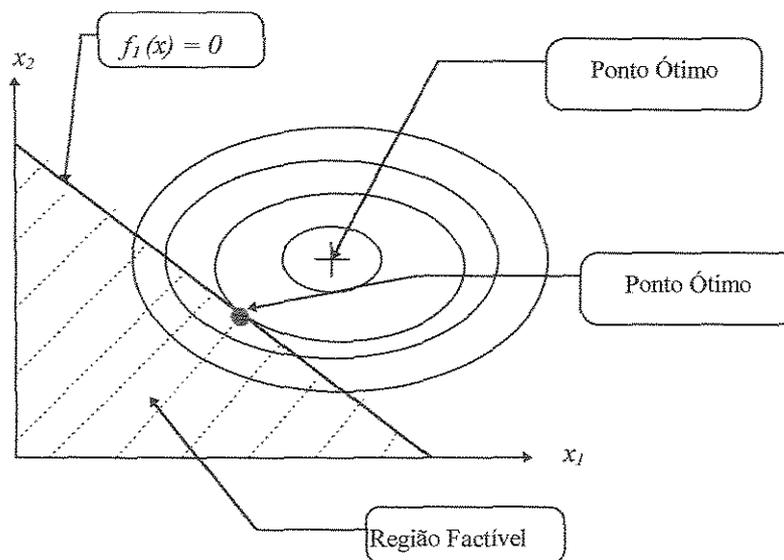
<sup>2</sup> Método de Cálculo Diferencial, Método dos Multiplicadores de Lagrange e a Programação Geométrica.



Fonte: BRAGA, 1987.

*Figura 3.1 - Posto Estacionário da Função de Única Variável Plurimodal,  $F(x_1)$*

Os problemas com restrições, em muitos casos<sup>3</sup>, facilitam a busca do ponto ótimo, ou seja, a região de pontos factíveis fica reduzida. Estes problemas não fazem parte deste estudo. (Figura 3.2).



Fonte: NOVAES, 1978.

*Figura 3.2 - Restrição Atuante*

<sup>3</sup> Por exemplo: exceto para processos indiretos, em que eventuais pontos de máximo ou mínimo localizados nas fronteiras não são necessariamente pontos estacionários e em caso que as restrições podem eventualmente introduzir extremos locais. (NOVAES, 1978).

A verificação de um ponto  $x^*$  mínimo (máximo) ou de inflexão de uma função (**Quadro 3.1**), é dada a partir das condições necessárias e suficientes para a existência destes pontos. A condição de otimalidade para a minimização sem restrições é discutida com base nas seguintes proposições:

1. *Condição necessária de primeira ordem* é satisfeita através da condição atribuída pela função objetivo:

Seja  $f: \mathbb{R}^n \rightarrow \mathbb{R}, f \in C^1$ . Se  $x^*$  é um minimizador local de  $f$  em  $\mathbb{R}^n$ , então  $\nabla f(x^*) = 0$ ;

2. *Condições necessárias de segunda ordem* também é satisfeita através da condição atribuída pela função objetivo:

Seja  $f: \mathbb{R}^n \rightarrow \mathbb{R}, f \in C^2$ . Se  $x^*$  é um minimizador local de  $f$  em  $\mathbb{R}^n$ , então

(i)  $\nabla f(x^*) = 0$ ,

(ii)  $\nabla^2 f(x^*)$  é *semidefinida positiva*;

3. *Condições suficientes* serão definidas a partir da análise das derivadas de 2ª, 3ª e n-ésima ordens.

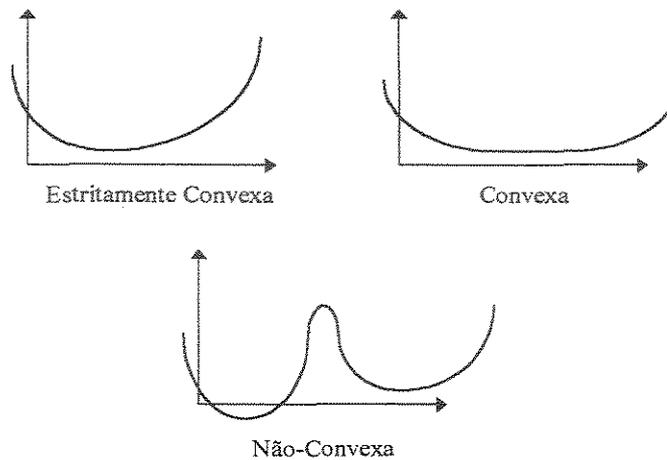
Seja  $f: \mathbb{R}^n \rightarrow \mathbb{R}, f \in C^2$ . Se  $x^* \in \mathbb{R}^n, \nabla f(x^*) = 0$ , e  $\nabla^2 f(x^*) > 0$ , então  $x^*$  é um minimizador local estrito de  $f$  em  $\mathbb{R}^n$ .

**Quadro 3.1 - Teste dos Pontos Estacionários  $F(x^*)$**

Ordem de Derivadas				Natureza do Ponto
$F'(x^*)$	$F''(x^*)$	$F'''(x^*)$	$F^{IV}(x^*)$	
0	>0	Existe	Qualquer	Máximo
0	<0	Existe	Qualquer	Mínimo
0	0	<0 ou >0	Existe	Inflexão
0	0	0	<0	Máximo
0	0	0	>0	Mínimo
0	0	0	0	Examinar $F^V(x^*)$

Fonte: BRAGA,1987.

Na busca do ponto ótimo global ou ótimo ( $x^*$ ) para toda a região de validade  $x$ , nos casos de função de uma única variável, os conceitos de concavidade e de convexidade de uma função exercem papel fundamental. Se a função objetivo for estritamente convexa implica dizer que existe um mínimo local e também um ponto de mínimo global, e, caso contrário, existe um máximo local ou ponto de máximo global (Figura 3.3).



**Figura 3.3 - Ilustrações de Figuras Estritamente Convexa, Convexa e Não Convexa**

Para os casos de funções de  $n$  variáveis ( $x_1, x_2, \dots, x_n$ ) os mesmos conceitos de convexidade e concavidade são estendidos, bem como a identificação dos mínimos (ou máximos) local e global.

Os métodos diretos sem restrições resolvem questões que satisfazem a expressão:

$$\begin{aligned}
 & \text{Max (ou Min)} \quad f(x_1, x_2, \dots, x_n) \\
 & \text{sujeito a} \quad x \in \Omega
 \end{aligned}
 \tag{3.3}$$

em que a equação (3.3) é a forma genérica dos problemas de *programação não-linear* ou *otimização global*,  $f: \mathcal{R} \rightarrow \mathcal{R}^n$  é uma função real e  $\Omega$  o conjunto de soluções factíveis, o qual é

um subconjunto aberto do  $\mathcal{R}^n$ . Quando  $\Omega = \mathcal{R}^n$  o problema passa a ser denominado de *problema de otimização irrestrito*.

São considerados dois tipos de soluções para este problema. Por definição (FRIEDLANDER, 1994):

1. Um ponto  $x^* \in \Omega$  é um *minimizador local* de  $f$  em  $\Omega$  se e somente se existe  $\varepsilon > 0$  tal que  $f(x) \geq f(x^*)$  para todo  $x \in \Omega$  tal que  $\|x - x^*\| < \varepsilon$ .

Se  $f(x) > f(x^*)$  para todo  $x \in \Omega$  tal que  $x \neq x^*$  e  $\|x - x^*\| < \varepsilon$ , diremos que se trata de um *minimizador local estrito* em  $\Omega$ .

2. Um ponto  $x^* \in \Omega$  é um *minimizador global* de  $f$  em  $\Omega$  se e somente se  $f(x) \geq f(x^*)$  para todo  $x \in \Omega$ .

Se  $f(x) > f(x^*)$  para todo  $x \in \Omega$  tal que  $x \neq x^*$ , diremos que se trata de um *minimizador global estrito* em  $\Omega$ .

A definição de maximizadores locais e globais é feita de forma análoga, ou seja, maximizar  $f$  é equivalente a minimizar  $(-f)$ .

Os algoritmos aplicados à resolução destes problemas de Programação Não Linear (PNL), variam substancialmente com suas motivações, aplicações e análises detalhadas, variando a partir de métodos muito simples até os mais complexos. Eles possuem um fator em comum: são algoritmos iterativos<sup>4</sup> descendentes<sup>5</sup>.

De maneira ideal uma seqüência de pontos gerados pelo algoritmo, neste caminho (processo), converge em um número finito ou infinito de passos para a solução de um problema original. O algoritmo iterativo é inicializado, especificando-se um ponto de partida (pontos

<sup>4</sup> Procedimento realizado pelo algoritmo o qual gera uma série de pontos (soluções), em que cada ponto é calculado sobre a base dos pontos precedidos por ele.

<sup>5</sup> Quer dizer que, cada novo ponto é gerado por algoritmo de valor correspondente a alguma função (estimada no melhor ponto atual) decrescente em valor.

arbitrários). Caso nas diferentes inicializações, o algoritmo garanta gerar uma seqüência de pontos convergentes à mesma solução então ele é dito *convergente globalmente*. Nem todos os algoritmos possuem esta propriedade desejável e, neste caso, alguns procedimentos são implementados com o objetivo de modificar, particularmente, o algoritmo através de recursos adicionais especiais que garantam a convergência global.

Quando não podemos resolver o sistema de equações produzida por (3.3), de maneira analítica, a forma adequada de se obter soluções numéricas é aplicar *algoritmos de procedimento de busca* para obter-se  $x_k^*$ , primeiro para  $k=1$  e depois para  $k>1$ .

Os métodos existentes para solucionar a expressão (3.3) são classificados segundo o tipo de informações que necessitam: *Métodos de Busca* ou *Método do Gradiente*<sup>6</sup>, métodos que usam a primeira derivada e *Métodos da Matriz Hessiana* que usam a segunda derivada da função objetivo.

O *algoritmo do Gradiente* é um dos métodos mais simples e é utilizado para resolver métodos que aplicam derivadas. Ele forma a base de muitos métodos diretos usados em otimização de problemas com e sem restrições, ou seja, é um processo iterativo de resolver as equações (3.3) através de computadores digitais e é representado por:

$$x_{k+1} = x_k + \gamma_k \cdot \nabla f(x_k^*) \quad (3.4)$$

Em que  $\gamma_k$  é um valor positivo que maximiza  $f(x_k + \gamma \nabla f(x_k))$ . Considera-se o valor mais difícil de se encontrar no processo de busca, em cada interação, representa o comprimento do passo a ser dado.

---

<sup>6</sup> É um método clássico de descida que tem por objetivo determinar um vetor de parâmetros  $w$  que minimize o erro quadrático sobre o conjunto de treinamento.

O *vetor gradiente*  $\nabla f(x)$  da equação (3.5), define a direção chamada de *direção do Gradiente*, em que a variação  $f(x)$  é a maior possível, para pequenos deslocamentos a partir de  $x^*$  em várias direções. A expressão é dada por:

$$\nabla f(x) = \left( \frac{\partial f(x)}{\partial x_k} \right), k = 1, 2, \dots, n \quad (3.5)$$

Neste algoritmo caminha-se na direção em que a função objetivo possui maior razão de crescimento. O vetor gradiente de uma função em um determinado ponto é normal a curva ou superfície de contorno que passa pelo ponto. Neste caso o método corresponde a escolher  $d_k$  na direção de  $-\nabla f(x_k)$ , indicando a direção de menor razão de crescimento (Figura 3.4), NOVAES (1978).

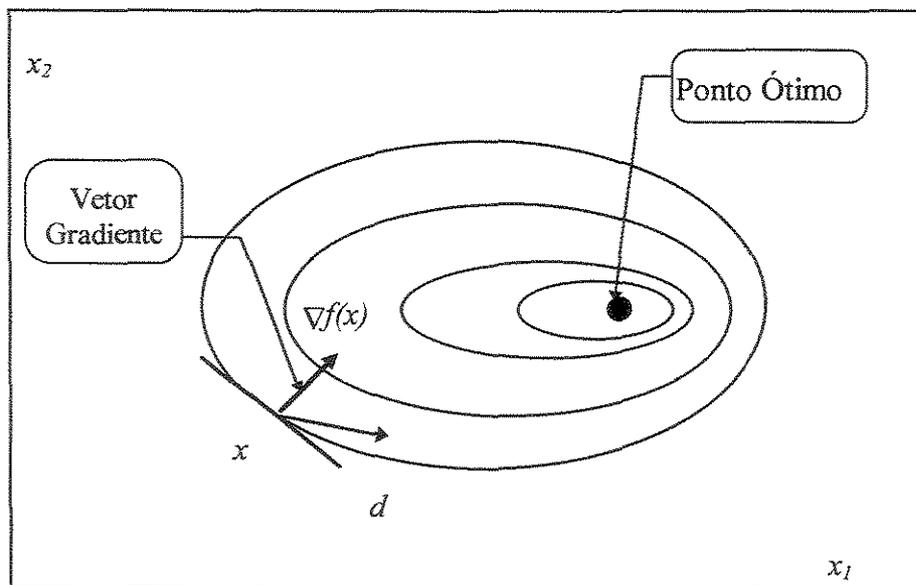


Figura 3.4 - *Projeção do Vetor Gradiente no Ponto  $x$ , num Problema de Maximização*

O procedimento de busca do gradiente é feito através de deslocamentos na direção do gradiente, até ele encontrar a solução ótima, em que  $\nabla f(x_k^*) = 0$ . Cada iteração promove mudanças na solução corrente de  $x_k$ . Sendo assim, para se requerer a finalização da iteração

aplica-se a *Regra da Parada*, que consiste em se estabelecer um *valor de tolerância*  $\varepsilon$  (ou erro pré-constituído representado por um escalar) para se definir à finalização da iteração, isto é:

$$\left| \frac{\partial f(x_k)}{\partial x_k} \right| \leq \varepsilon, \quad k = 1, 2, \dots, n \quad (3.6)$$

A matriz *Hessiana* de uma função  $f(x)$  que possui derivadas parciais de segunda ordem, é simétrica e tem por definição a seguinte expressão:

$$H(x) = \nabla^2 f(x) \equiv \left[ \frac{\partial^2 f}{\partial x_i \cdot \partial x_j} \right] \quad (i, j = 1, 2, \dots, n) \quad (3.7)$$

A matriz é classificada *definida negativa*, se seus determinantes e as derivadas em relação a uma mesma variável apresentarem valores negativos, respectivamente. Se um desses termos for igual a zero, a matriz é classificada como *semidefinida negativa*. Caso contrário, é classificada de matriz *Hessiana definida positiva e semipositiva*.

Considerando um problema de otimização multivariável, são pertinentes os seguintes teoremas:

- *Teorema 1:* se  $f(x)$  é uma função contínua definida em uma região fechada e limitada, então essa função apresenta um máximo e um mínimo global nessa região;
- *Teorema 2:* se  $f(x)$  apresenta um máximo ou mínimo local em  $x^*$  e se  $\nabla f(x)$  existe em alguma vizinhança  $\varepsilon$  de  $x^*$ , então  $\nabla f(x^*)=0$ ;
- *Teorema 3:* se  $f(x)$  possui derivas parciais de segunda ordem em uma vizinhança  $\varepsilon$  em torno de  $x^*$ , então  $\nabla f(x^*)=0$ , como também  $H(x^*)$  for definida negativa, então  $f(x)$  possui um máximo local em  $x^*$ .

Tomando como base os dois primeiros teoremas, conclui-se que o valor máximo global de uma função contínua  $f(x)$  é atingido quando  $\nabla f$  é nulo ou não existe.

Grande parte dos métodos que resolvem funções com uma variável, chamados de métodos de busca unidimensional, necessita da técnica de otimização para definir o local mínimo ou máximo da função e aplicam métodos numéricos com base na técnica de busca seqüencial. Nesta técnica, a partir de um determinado intervalo finito  $\Delta$ , admite-se que a função seja unimodal e reduz-se gradativamente esse intervalo comparando-se os valores da função objetivo. Dentre os métodos citados na literatura, estão o método de busca de Fibonacci, o método de busca do meio termo (*golden section*) e o método DSC-Powell.

Os métodos de otimização não lineares de problemas com múltiplas variáveis de decisão independentes necessitam de um recurso de busca da direção do ponto máximo ou mínimo da função objetivo, no qual um dos procedimentos é conduzido por intermédio da aplicação do gradiente. Os algoritmos de PNL citados na literatura, que não apresentam restrições e que a direção de busca realizada a partir das técnicas baseadas em derivadas de primeira e segunda ordem, são o método de Newton-Raphson, o método do maior gradiente (*steepest descent method*), o método do gradiente conjugado e o método Quase-Newton, dentre outros. Para os casos de PNL sem restrição, os métodos de busca sem derivadas são o método de Hooke-Jeeves, o método de Rosenbrock, o método de Powell e outros. Ainda existem aqueles algoritmos de PNL que não possuem restrições, tais como, o método da programação por aproximação, o método das funções de penalidades e o método dos gradientes reduzido generalizado. BAZARAA (1983), apresenta diversos métodos de busca com aplicação de derivadas e outros sem aplicação de derivadas para a solução de problemas multidimensionais.

No modelo SMAPm, o algoritmo de otimização aplicado na busca automática de solução da função não linear multivariável é o algoritmo de Rosenbrock. Este algoritmo, que aplica a derivada na PNL, é baseado na busca exploratória na qual pequenos “passos” são atribuídos durante os processos (ROSENBROCK, 1960) - **Figura 3.5.**

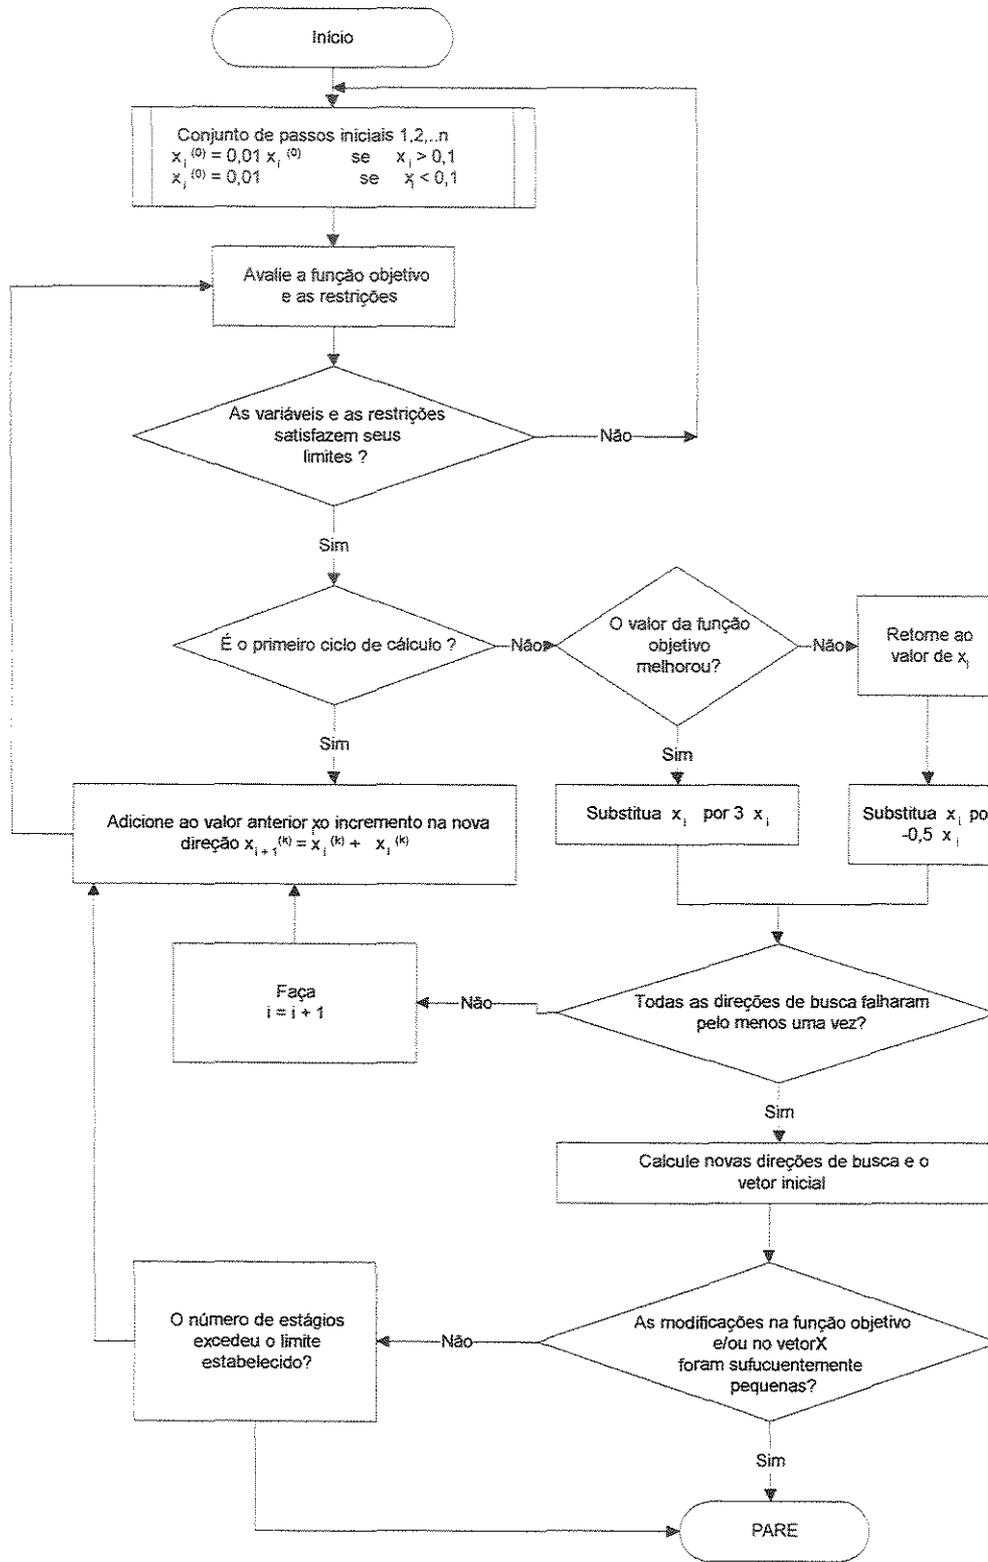


Figura 3.5 – Fluxograma Esquemático do Método de Rosenbrock

Os *Métodos de Busca Direta* para funções com  $n$  variáveis são formados por processos iterativos e muito usados na calibração de modelos hidrológicos. Estes modelos relacionam precipitação e vazão de uma bacia hidrográfica, podendo ser de natureza determinística<sup>7</sup>.

Com base no conceito na proposição de *direções de descida* a partir de  $x$ , FRIEDLANDER (1994) apresenta um modelo de algoritmos com buscas direcionais:

“...dado  $x \in \mathfrak{R}^n$ , se  $\nabla f(x) \neq 0$ , sabendo-se que pela proposição das condições de otimalidade necessárias de primeira ordem<sup>8</sup>,  $x$  não representa um minimizador local de  $f$  em  $\mathfrak{R}^n$ . Logo, em toda a vizinhança de  $x$  existe  $z \in \mathfrak{R}^n$  tal que  $f(z) < f(x)$ . Neste caso o objetivo é indicar as direções a partir de  $x$ , entre as quais se possa encontrar um ponto  $z \in \mathfrak{R}^n$  que confirme  $f(z) < f(x)$ ”.

Portanto, a proposição matemática é da seguinte forma:

sejam  $f: \mathfrak{R}^n \rightarrow \mathfrak{R}$ ,  $f \in C^1$ ,  $x \in \mathfrak{R}^n$  tal que  $\nabla f(x) \neq 0$ ,  $d \in \mathfrak{R}^n$  tal que  $\nabla f(x) d < 0$ . Então  $\bar{\alpha} > 0$  tal que  $f(x + \alpha d) < f(x)$  para todo  $\alpha \in (0, \bar{\alpha}]$ . O vetor direção é representado por  $d$ .

A partir de valor inicial dos parâmetros os algoritmos possuem minimizam uma função objetivo, a qual estabelece a diferença, por exemplo, entre os valores dos hidrogramas observados e calculados pelo modelo e, com isto, requerer a variação dos parâmetros por meio de algoritmos matemáticos específicos. MAGALHÃES (1989) cita diversos deles pertencentes ao grupo de *busca direta*.

ROMERO (1993), FRIELANDER (1994) e HILLIER (1995) apresentam alguns passos para definir uma nova estimativa  $x_{k+1}$  dada pelo algoritmo do modelo:

#### 1. Inicialização:

- selecionar uma estimativa inicial da solução,  $x_0$  e a seguir vá para a Regra da Parada;

<sup>7</sup> Segundo DOOGE (1973) um sistema é dito determinístico quando, para a mesma entrada o sistema produz sempre a mesma saída; se o sistema for estocástico o relacionamento entre a entrada e a saída não é previsível com exatidão.

2. *Iteração:*

- Regra da Parada - encontrar uma direção de busca  $d_k \in \mathcal{R}$  partindo de  $x_k$ , que garanta uma diminuição da função. Isto é feito se o gradiente  $\nabla f(x_k^*)$  for diferente de zero. Se a  $\|\nabla f(x_k^*)\|$  for suficientemente pequena, então a solução ótima foi obtida e o processo é interrompido;
- determinar o tamanho do passo  $\gamma_k > 0$ , na direção  $d_k$ , de modo que uma diminuição suficiente na função objetivo seja obtida (este subproblema é chamado de *busca linear*), i.e.,

$$f(x_k + \gamma_k d_k) < f(x_k) \quad (3.8)$$

- atualizar a solução de acordo com

$$x_{k+1} = x_k + p_k, \text{ em que } p_k = \gamma_k d_k = \Delta_{k+1} \quad (3.9)$$

e vá para a Regra da Parada.

Outra proposição de busca do melhor de uma função é conduzida por FRIELANDER (1994), que considera o seguinte algoritmo para minimizar um função  $f$ , definida em  $\mathcal{R}^n$ , em que  $x_k \in \mathcal{R}^n$  tal que  $\nabla f(x_k) \neq 0$ , cujos passos para o cálculo de uma nova estimativa  $x_{k+1}$  será:

- calcular  $d_k = -\nabla f(x_k)$ ;
- determinar o tamanho do passo  $\gamma_k$  que é o minimizador de  $f(x_k + \gamma d_k)$  sujeita a  $\gamma \geq 0$ . Este subproblema ou processo é chamado de *busca linear exata*;
- atualizar a solução de acordo com  $x_{k+1} = x_k + \gamma_k d_k$ . Nota-se que neste processo pode não ter solução e neste caso o algoritmo aplicado nem sempre está bem definido.

---

<sup>3</sup> Que se  $x^*$  representa um minimizador local de  $f$  em  $\mathcal{R}^n$ , então  $\nabla f(x) = 0$ .

São métodos bastante rápidos, portanto muito utilizados e, em geral, neles somente condições adicionais impostas sobre  $f(x)$  podem garantir que o mínimo (ou máximo) local é também o global.

Algumas das expressões usadas para o cálculo da direção de busca  $d_k$  são apresentadas no **Quadro 3.2**, correspondendo a cada algoritmo de PNL sem restrições com direção de busca a partir de derivadas, sejam elas de primeira ordem ou de segunda ordem.

**Quadro 3.2 - Algoritmos de Otimização Aplicados em Treinamento da Rede**

<i>Métodos</i>	<i>Direções</i>
Gradiente Simples	$p_k = \gamma d_k = -\gamma \nabla f(x_k^*)$
Gradiente Modificado	$p_k = \gamma d_k = -\gamma [\nabla f(x_k^*) + m p_{k-1}]$
Steepest Descent	$p_k = \gamma d_k = -\gamma_k \nabla f(x_k^*)$
Gradiente Conjugado	$p_k = \gamma d_k = -\gamma_k [\nabla f(x_k^*) + b_k p_{k-1}]$
Quase Newton	$p_k = \gamma d_k = -\gamma_k S(x_k) \nabla f(x_k^*)$
Newton	$p_k = \gamma d_k = -\gamma_k [H(x_k)]^{-1} \nabla f(x_k^*)$

Fonte: ROMERO, 1993

Os grupos de algoritmos de PNL que aplicam derivadas são classificados segundo a “ordem” de informação que eles usam, ou seja, a ordem da derivada da função objetivo. Como já visto anteriormente, existe um grupo de algoritmos que usa a primeira derivada da função a ser minimizada, esses estão incluídos na classificação dos *métodos de primeira ordem* (método padrão de *backpropagation*, *backpropagation* padrão com *momentum*, método do gradiente, dentre outros). Já os que aplicam a segunda derivada na minimização da função objetivo, estão incluídos na classificação dos *métodos de segunda ordem* (método de Newton, método do gradiente conjugado, método do gradiente conjugado escalonado, método Quase-Newton e outros).

O modelo de RNA's aplica como método de otimização de PNL não linear irrestrito para o treinamento do tipo de rede escolhida no estudo de caso, o *método do gradiente conjugado escalonado*, proposto por MOLLER (1993). Este método faz parte da classe de algoritmos chamados de *métodos segunda ordem*, os quais são considerados bastantes eficientes na aplicação da técnica de RNA's.

O algoritmo aplicado neste método é descrito abaixo (MOLLER, 1993; BISHOP, 1997 e SILVA, 1998):

1. Escolha um vetor de parâmetros inicial  $\theta_0$  e escalares  $0 < \sigma < 10^{-4}$  e  $\lambda_0 = 0$ ;
2. Faça: o conjunto de  $\mathbf{P}_0 = \mathbf{r}_0 = -\nabla f(x_0)$ ;  $k = 0$ ; sucesso = 1  $\rightarrow$  verdadeiro;
3. Se sucesso = 1, então calcule a informação da segunda ordem:

$$\sigma_k = \frac{\sigma}{\|d_k\|}; \quad s_k = \frac{\nabla f(x_k + \sigma_k d_k) - (\nabla f(x_k))}{\sigma_k} + \lambda_k d_k; \quad \delta_k = \mathbf{P}_k^T \cdot s_k;$$

4. Se  $\delta_k \leq 0$ , então faça a matriz *Hessiana* definida positiva:

$$\lambda_k^N = 2 \left[ \lambda_k - \frac{\delta_k}{\|d_k\|^2} \right]; \quad \delta_k = \delta_k + (\lambda_k^N - \lambda_k) \cdot \|d_k\|^2; \quad \lambda_k = \lambda_k^N;$$

5. Calcule o tamanho do passo (taxa de ajuste):

$$\mu_k = \mathbf{P}_k^T \cdot \mathbf{r}_k; \quad \alpha_k = \frac{\mu_k}{\delta_k};$$

6. Calcule o parâmetro de comparação:

$$\Delta_k = \frac{2\delta_k [f(x_k) - f(x_k + \gamma_k \cdot d_k)]}{\mu_k^2};$$

7. Se  $\Delta_k \geq 0$  ( o erro pode ser reduzido), então atualize o vetor de pesos:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \gamma_k \cdot \mathbf{d}_k; \quad \mathbf{r}_{k+1} = -\nabla f(\mathbf{x}_{k+1});$$

8. Se  $(k \bmod \mathbf{P}) = 0$ , então reinicialize o algoritmo;

$$\mathbf{P}_{k+1} = \mathbf{r}_{k+1}$$

Senão, defina uma nova direção conjugada de busca:

$$\beta_k = \frac{\|\mathbf{r}_{k+1}\|^2 - \mathbf{r}_{k+1}^T \cdot \mathbf{r}_k}{\mu_k}; \quad \mathbf{P}_{k+1} = \mathbf{r}_{k+1} + \beta_k \cdot \mathbf{P}_k;$$

9. Se  $\nabla_k \geq 0,75$ , então reduza o parâmetro

$$\lambda_k = 0,5 \lambda_k;$$

10. Se  $\nabla_k \leq 0,25$ , então aumente o parâmetro

$$\lambda_k = 4 \lambda_k;$$

Senão, uma redução no erro não é possível:

Sucesso = 0 (falso);

11. Se  $\mathbf{r}_{k+1} > \varepsilon$ , em que  $\varepsilon \rightarrow 0$ , então faça:

$$k = k+1; \text{ retorne ao passo 3};$$

Senão, o procedimento de ajuste chegou ao fim e  $\mathbf{x}_{k+1}$  é o ponto de mínimo.

Notação:  $\varepsilon$  = erro pré-estabelecido ou tolerância;  $\gamma$  = é um escalar que indica o comprimento do passo;  $\beta$  = coeficiente *momentum*;  $\mathbf{x}$  = é um vetor de parâmetros;  $\lambda$  = coeficiente de escalonamento ou parâmetros de ajuste;  $\mathbf{P}$  = matriz de dados de entrada;  $\mathbf{d}$  = é a direção de busca e  $f$  = é a superfície de erro de um problema de aproximação.

### 3.3 Fundamentos de RNA's

O conhecimento da estrutura de neurônios teve um período de intensa investigação entre os cientistas há muitos anos. A natureza elétrica dos impulsos nervosos foi postulada, por volta de 1850, por Emil du Bois-Reymond e Hermann von Helmholtz. Mais tarde, 1901, Sanatiago Ramón y Cajal documentou que o trabalho de uma rede específica de células nervosas determinava a direção para a transmissão de informação e, com isso, pode definir que os neurônios constituem um sistema hierárquico. As transmissões químicas de informações que se processam nas sinapses<sup>9</sup> foram estudadas entre 1920 e 1940. Mas foi através do modelo de Hodgkin-Huxley, considerado um dos primeiros modelos em redes neurais artificiais, que a teoria da dinâmica dos impulsos nervosos pode ser simulada com redes elétricas simples (ROJAS, 1996).

A publicação do primeiro artigo sobre propriedades matemáticas de redes neurais é atribuída a Warren McCulloch e Walter Pitts (1943) apud KOVÁCS (1996). Este artigo foi inspirado nas propriedades eletrofisiológicas dos neurônios nas teorias que indicavam ser booleanas a natureza essencial da inteligência. Eles foram os primeiros a propor um modelo computacional para o neurônio biológico (KOVÁCS, 1996).

Ao final da década de 50 J. Von Neumann foi considerado um dos principais cientistas a contribuir para o modelo do computador digital através da *arquitetura de Von Neumann*. Com a publicação pós-morte do seu livro “*The Computer and the Brain*“, ficaram esclarecidas, finalmente, as diferenças entre o cérebro e o computador. Outro trabalho significativo foi apresentado por F. Rosenblatt, que propôs a teoria sobre o *Perceptron* dando uma nova abordagem ao problema de reconhecimento padrão e, em outro trabalho, consagrou-se com a demonstração do *teorema de convergência do perceptron*. Foi em 1949, através de um trabalho de D.O. Hebb<sup>10</sup>, que a regra de aprendizagem fisiológica para modificação sináptica se consolidou,

---

<sup>9</sup> Sinapses (*Synapses*) são elementos estruturais e unidades funcionais as quais intermediam as interações entre os neurônios, através dos impulsos nervosos que são transmitidos.

<sup>10</sup> *The Organization of Behavior: A Neural psychological Theory*. New York: Wiley

sendo seguido por W. R. Ashby<sup>11</sup>, em 1952, com um trabalho no qual enfatizava o aspecto dinâmico de um organismo vivendo como uma máquina e o conceito relacionado à estabilidade. Em 1961 M.L. Minsky<sup>12</sup> publicou um trabalho sobre inteligência artificial em que fazia referências sobre o que é agora denominada rede neural. (HAYKIN, 1994).

B. Widrow e M. E. Hoff introduziram, em 1960, um algoritmo o qual utilizava como função custo a *média dos mínimos quadrados* e o usaram na formulação do modelo linear *Adaline* (ADAPTative LINear Elemente), que consiste em uma máquina para classificar padrões lineares (WIDROW e HOFF JR, 1960). Porém, em 1962, Widrow estruturou o *Madaline*, que representa uma rede de *Adalines*. Estes estudos foram os precursores para a formulação da rede de perceptrons, conhecida como Redes de Perceptrons de Múltiplas Camadas ou Redes do tipo MLP (WIDROW, 1962). Mas a grande contribuição de Widrow foi com a criação do princípio de treinamento para as redes *Adalines* conhecido por *Regra Delta*, que após algum tempo foi generalizada para redes neurais mais complexas (KOVÁCS, 1996).

Até o final da década de 60 se admitia, com base em estudos anteriores, que as RNA poderiam calcular qualquer coisa. Foi então que MINSKY e PAPER (1969) demonstraram matematicamente que existiam limites fundamentais sobre o que um perceptron de camada única pode computar, o que levou a desencorajar alguns pesquisadores para trabalhos futuros.

Foi durante a década de 1970 que alguns fatores de ordem tecnológica e financeira contribuíram para que houvesse algum desânimo na continuidade dos estudos voltados à RNA, na perspectiva da física e das engenharias. Ainda assim, a busca por novos algoritmos de aprendizagem; fundamentos teóricos e modelos aplicados a RNA foram registrados em alguns trabalhos.

A década de 80 foi de ressurgimento de novas teorias e modelos de RNA, bem como desenvolvimento de novos algoritmos de aprendizado (GROSSBERG, 1980).

---

<sup>11</sup> *Design for Brain*. New York: Wiley.

<sup>12</sup> Steps towards artificial intelligence. *Proceedings of the Institute of Radio Engineers*. (49), p. 8-30.

J.J Hopfield em seu trabalho *Neural Networkkan Physical Systems with Emergent Collective Computational Abilities*, publicado em 1982, desenvolveu a idéia de uma função energia para formular novos percursos visando melhorar a performance computacional das redes recorrentes com concepção sináptica simétrica, o que originou as *Redes Hopfield*. Outro importante trabalho, apresentado em 1982, foi o de T. Kohonen sobre mapas de auto-organização usando estruturas treliçadas uni ou bi-dimensionais (HAYKIN,1994).

A partir da divulgação do *algoritmo back-propagation*, em 1986, através dos dois trabalhos de RUMELHART, HINTON e WILLIAMS (1986) e RUMELHART e MCCLEALAND (1986) estes foram considerados como um dos principais responsáveis pelo ressurgimento dos estudos sobre RNA na década de 1980, juntamente com o trabalho de J. J. Hopfield em 1982.

Várias são as aplicações de redes neurais divulgadas na literatura. Na área aeroespacial está sendo usada em simulação do trajeto de vôos e sistemas de controle de aeronaves, na engenharia automotiva em sistemas de direção automática de automóveis, no sistema bancário em avaliações de aplicações, e se estendendo ao sistema financeiro em previsão do preço corrente. Na eletrônica é bastante utilizada em controle de processos, máquina de visão, síntese de vozes e modelagem não linear; na área de robótica existem estudos em controle de trajetória e controladores manipulador, na medicina em análise de eletroencefalograma e eletrocardiograma, modelos de próteses e otimização de tempo de transplantes, nas ciências sociais em previsão do custo da violência no trânsito e violência provocada pelos conflitos agrários (MATHWORKS (b), 1998).

Particularmente, na hidrologia tem sido uma ferramenta muito útil em modelos de previsão de vazão destinados a operação de reservatórios em tempo real, como ferramenta alternativa, na construção de programas especialistas destinados a apoiar as decisões no gerenciamento de recurso hídricos, na previsão de eventos extremos como secas e cheias e também, na previsão de níveis em canais de fuga. No caso preenchimento de falhas, o trabalho de KULIGOWSKI e BARROS (1998) especifica uma técnica de substituição de dados espaciais

ausentes - dados de precipitações, a partir de medidas bem próximas, usando o algoritmo de *retropropagação do erro – backpropagation*, no treinamento de rede neurais.

Na solução de problema de otimização multiobjetivo, algoritmos baseados em RNA estão sendo aplicados no gerenciamento da qualidade de água com vista ao controle da poluição e no planejamento dos recursos hídricos. WEN e LEE (1998) desenvolveram um modelo de redes neurais artificiais, cujo algoritmo de treinamento é *backpropagation - BP*, no qual foi constatado a grande capacidade de simular as preferências do tomador de decisão para resolver as soluções da programação multiobjetiva (na qual existe alta não linearidade da relações entre os valores dos objetivos e seus pesos relativos).

No monitoramento ambiental, CLAIR e EHRMAN (1998), apresentaram um estudo de investigação no qual as mudanças climáticas sazonais podem afetar a vazão dos rios; o nitrogênio e o carbono aquáticos liberados na bacia, utilizando na modelagem a técnica de RNA. Os resultados alcançados reproduziram os padrões anuais de descargas de carbono orgânico dissolvido e de nitrogênio orgânico dissolvido em bacias do Canadá. Dois modelos de monitoramento das condições biológicas de rios, devido a poluição orgânica, foram desenvolvidos aplicando a técnica de RNA com treinamento da rede através do algoritmo BP (WALLEY e FONTANA, 1998).

Os estatísticos usam RNA como modelo de classificação e regressão não linear. Para os engenheiros o campo de aplicação é muito extenso; pois ela pode ocorrer em processamento de sinais, controle automático, previsão de séries temporais e etc. No campo das ciências médicas, os neurofisiologistas usam a rede neural para descrever e explorar as funções do cérebro a nível médio, como por exemplo, motricidade e memória..

O campo de aplicação de redes neurais vai além das áreas da ciência. Podem ser utilizados em serviços públicos como, segurança, educação e saúde, transportes, entretenimento, exploração de óleo e gás.

### 3.3.1 O Neurônio Artificial

Um neurônio é uma unidade de processamento de informação que é fundamental na operação de redes neurais (HAYKIN, 1994). Os neurônios biológicos (Figura 3.6) recebem sinais e produzem a resposta e, este processo é realizado através das interconexões que existem na estrutura do sistema nervoso.

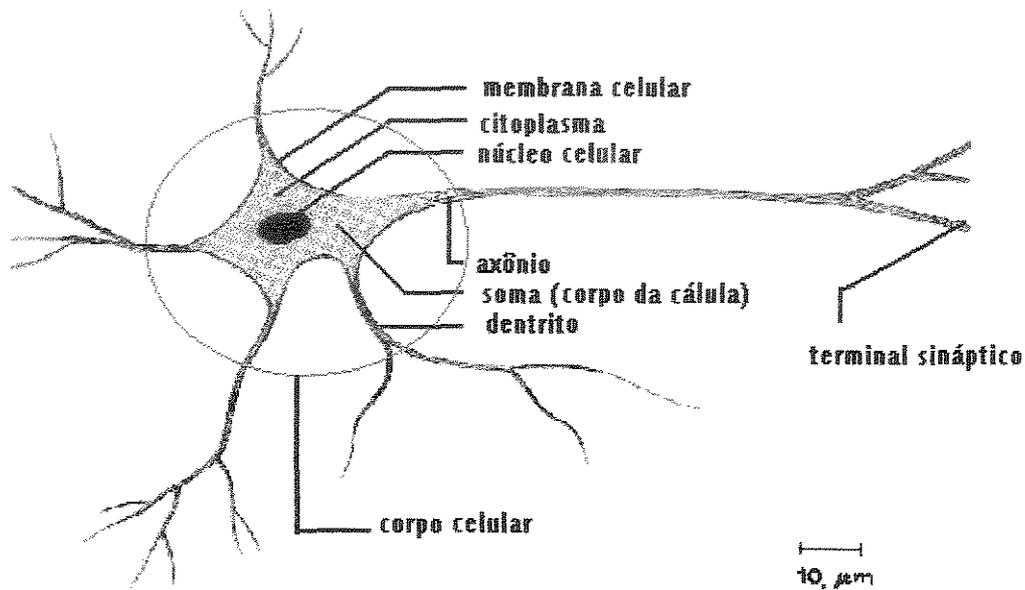


Figura 3.6 - Estrutura Geral do Neurônio Biológico Genérico

O neurônio, como toda célula biológica, é envolvido por uma fina membrana celular. Na rede neural biológica as informações são armazenadas e os pontos de contato entre os diferentes neurônios são chamados de *sinapses*, que nada mais são do que regiões eletroquimicamente ativas.

Dentro do sistema nervoso, encontram-se neurônios de diferentes tipos e funções. Sua estrutura mínima é compreendida das *sinapses*, do *corpo da célula*, também chamado de *soma*, que é onde ocorre o centro dos processos metabólicos da célula nervosa e, a partir dele, várias extensões de filamentos são enraizadas dando origem aos *dendritos*, que são canais transmissores de chegada das informações, ao *axônio* (também referido como *fibra nervosa* ou *linha de*

*transmissão* e cada célula possui apenas um) que serve para conectar a célula nervosa à outras do sistema e nas extremidades dos *dentritos* encontram-se os *terminais sinápticos*.

As entradas no neurônio biológico são feitas através das conexões sinápticas que conectam todos os *dentritos* ou a *árvore dentrital* aos *axônios* de outras células nervosas. As *sinapses* estão compreendidas entre suas membranas: a *pré-sináptica*, aonde chegam os estímulos vindo de outra célula e, a *pós-sináptica* que é a do *dentrito*. Os sinais emitidos pelo corpo celular que chegam e percorrem os *axônios* são impulsos elétricos (substância neurotransmissora produzida) chamados de impulsos nervosos ou potenciais de ação. Estes sinais nada mais são do que as informações que o neurônio irá processar, de alguma forma, para em seguida produzir como saída um outro impulso nervoso no seu *axônio*. O neurotransmissor poderá diminuir ou aumentar a polaridade da membrana pós-sináptica, através da inibição ou da excitação da produção dos pulsos no outro neurônio conectado.

### 3.3.2 Topologia das RNA's

As redes neurais artificiais são constituídas de elementos simples operando em paralelo, que armazenam conhecimentos através de experiências, sendo estes elementos inspirados no sistema nervoso biológico. As RNA's são uma tentativa de modelar a capacidade de processamento das informações do sistema nervoso (Figura 3.7).

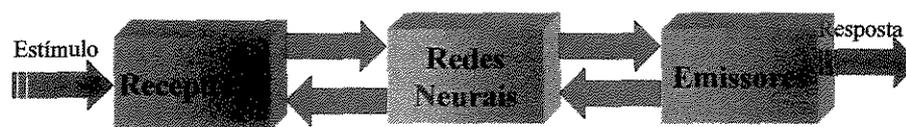


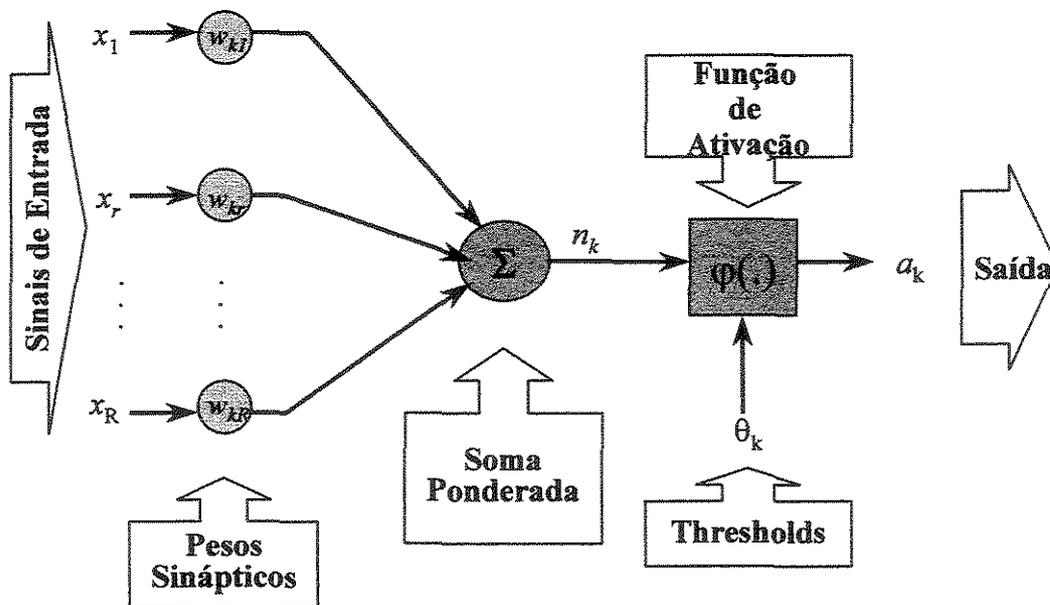
Figura 3.7 - Elementos de Conexão de RNA's

Fonte: HAYKIN, 1994

As RNA's constituem-se de uma técnica computacional cuja representação do respectivo modelo matemático está baseada na estrutura neural de organismos inteligentes, nos quais a

aquisição do conhecimento está vinculada a experiência adquirida. Comparando a estrutura de uma RNA com a do neurônio biológico, percebeu-se que ela é constituída de *canais de entrada*, *corpo da célula* e *canais de saída*, as *sinapses* irão ser simuladas através dos contatos entre os pontos do *corpo da célula* e as conexões de entrada e saída e, os *pesos* estarão associados a esses pontos.

A **Figura 3.8** mostra o modelo de um neurônio artificial e seus elementos básicos. Sua estrutura é constituída de um conjunto de entradas ( $x_R$ ) que multiplicadas por um peso sináptico correspondente ( $w_{kR}$ ) produz entradas ponderadas. Na seqüência é realizada uma soma ponderada destes sinais resultando em um valor  $n_k$  o qual é comparado com um valor limite (limiar  $\theta_k$ ) para então ativar o neurônio resultando em  $a_k = \varphi(n_k)$ . Se o valor exceder o valor do limiar do neurônio ocorrerá a ativação, caso contrário, não.



**Figura 3.8 - Arquitetura de um Neurônio Artificial com Múltiplas Entradas Não Lineares**

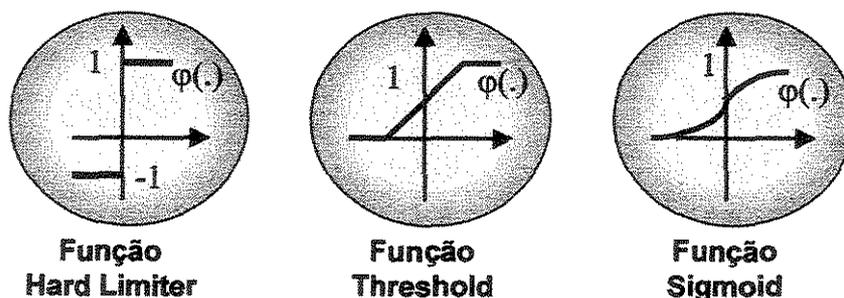
Em que:

$x_R$  são os vetores de dados de entrada da rede (*inputs*);

$w_{iR}$  são os pesos sinápticos escalares do neurônio, referentes a cada elemento de entrada;  $x$ . São parâmetros da rede neural ligados a uma conexão entre os neurônios  $r$  e  $i$  e caso seu valor seja positivo indica uma sinápsse excitatória e caso contrário uma sinápsse inibitória. São os únicos parâmetros ajustáveis da rede;

$\theta_k$  é um *threshold* e *bias* (limiar) que representam entradas adicionais de polarização ( $x_0=1$  ou  $x_0=-1$ ) é um parâmetro aplicado externamente a um neurônio  $k$  e que possui um efeito de rebaixamento da rede de entrada de uma função de ativação, por outro lado, estas entradas podem ser aumentadas pelo emprego do termo *bias* – um *bias* é um negativo de um *threshold*. Os limiares adicionados ao somatório dos produtos ( $w*x$ ) formarão a entrada escalar  $n$ . Esta soma é o argumento da função de transferência  $\phi(.)$ ;

$\phi(.)$  é *função de transferência* ou *função de ativação* e produz o vetor de saída  $a_k$ . Esta função é um limitador de amplitude de um neurônio de saída e geralmente fechada em um intervalo de  $[0,1]$  ou alternativamente  $[-1,1]$ . Existem vários tipos de funções, mas as comumente usadas na modelagem de neurônios são as funções *Sigmoid*, *Threshold Logic* e *Hard Limiter*. **Figura 3.9.**



**Figura 3.9 – Tipos de Funções de Ativação**

$\theta_i$  corresponde ao parâmetro de valor limiar do neurônio,  $i$  e,

$\Sigma$  é o somatório dos produtos entre os vetores linha dos pesos ( $w$ ) e os vetores coluna ( $x$ ) de entrada da rede ( $w*x$ ), mais a influência do limiar, expressa por

$$n_k = \sum_{r=1}^R w_{rj} \cdot x_r - \theta_k \quad (3.10)$$

O valor de  $n_k$  passa a ser argumento de uma Função de Ativação,  $a_k = \varphi(n_k)$ , ocorrendo a propagação desses valor para os próximos neurônios.

Para WASSERMAN (1989) as redes neurais artificiais se assemelham ao cérebro por dois aspectos: o conhecimento é adquirido pela rede através de um processo de aprendizagem; a intensidade das conexões, conhecidas como pesos sinápticos, são usadas para armazenar aprendizagem, ou seja, de adquirir o conhecimento.

A estrutura da rede, composta de interconexões de neurônios, é chamada de *arquitetura da rede neural*, podendo variar quanto ao número de camadas, neurônios em cada camada, função de transferência de um neurônio para o outro<sup>13</sup> e número de saídas. A *Rede Multicamadas* (RMC) ou do inglês *Multilayers Perceptrons* (MLP) está associada ao algoritmo de treinamento *Backpropagation* (BP).

As arquiteturas de redes estão divididas em quatro diferentes classes :

### 1. *Redes Feedforward de Camada Única*

São formadas por uma camada de entrada de nós-origens ligadas à camada de saída de neurônio - é uma rede do tipo *feedforward* – cuja propagação direta das conexões é realizada entre camadas adjacentes. Uma de suas vantagens é que possui memória associativa, ou seja, ela associa um padrão de saída (vetor) com padrão de entrada (vetor).

### 2. *Redes Feedforward Multicamadas*

As redes neurais artificiais com perceptron de multicamadas (MLP, do inglês *Multilayer Perceptron*) possuem uma ou mais camadas escondidas, enquanto que os cálculos nos nós

<sup>13</sup> No caso de rede com duas camadas, por exemplo, a primeira camada com neurônios possui uma função de transferência do tipo *sigmoide* e a segunda linear.

correspondentes são chamados de neurônios escondidos ou unidades escondidas. São geralmente usadas para determinar um mapeamento entre dois conjuntos de dados.

### 3. *Redes Recorrentes*

Estas redes são semelhantes às multicamadas, apenas com a diferença de que estas possuem, pelo menos um *loop* de realimentação, ou seja, suas saídas são conectadas com as entradas. As redes mais comuns são as redes Elman e as redes Hopfield (BISHOP, 1995).

### 4. *Estrutura Treliçada*

A treliça consiste em uma dimensão, duas ou mais dimensões de ordem de neurônios com um correspondente conjunto de nós origem que fornecem sinais de entrada para uma ordem. É uma rede com neurônio de saída combinados em linhas e colunas. (HAYKIN, 1994).

### 3.3.3 *Rede do Tipo Perceptron Multicamada (MLP)*

Foi no fim da década de 50 que Frank Rosenblatt deu continuidade à teoria de McCULLOCH e PITTS (1943), que ficou conhecida como o *neurônio de McCulloch e Pitts*, era um dispositivo binário, ou seja, a saída poderia ser *pulso* ou *não pulso* e os seus inúmeros sinais de entrada possuíam um ganho arbitrário e poderiam ser excitatórias ou inibitórias (**Figura 3.10**).

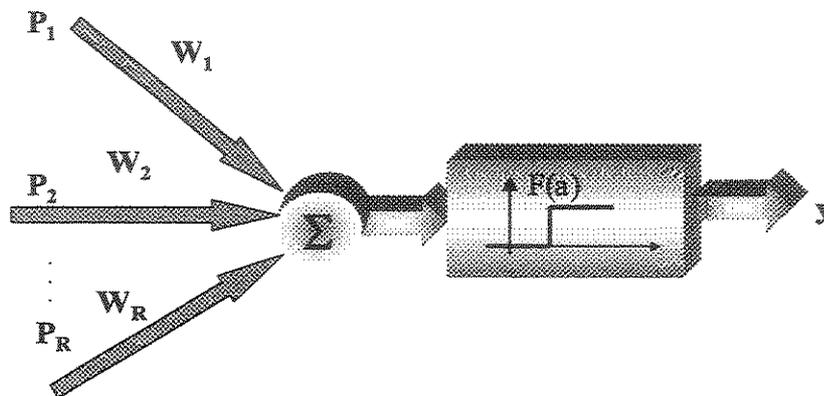


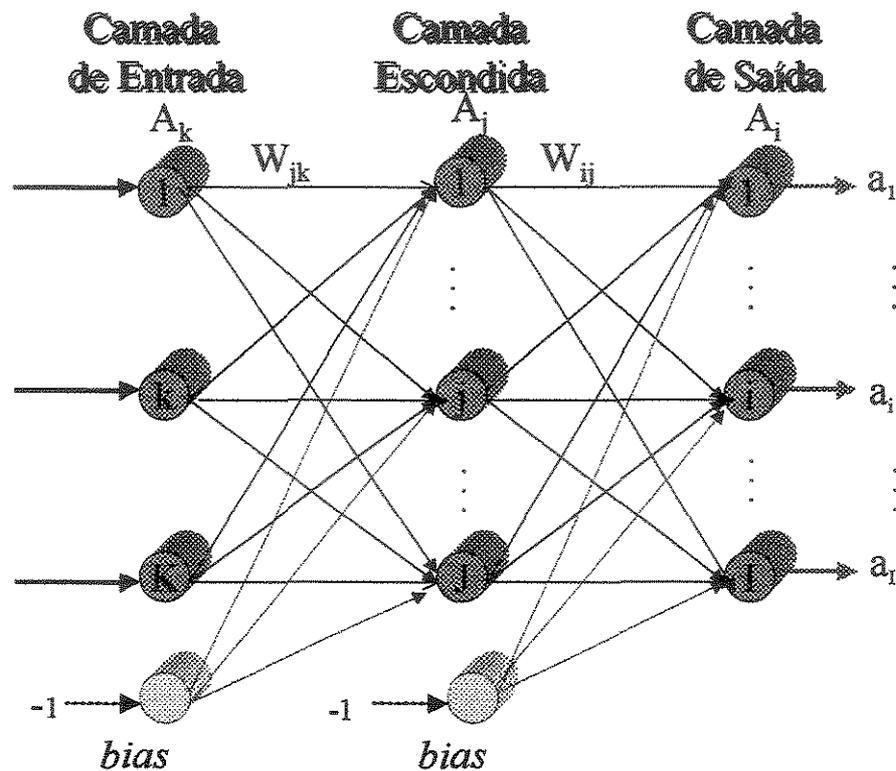
Figura 3.10 – Representação Funcional de um Neurônio – Perceptron de McCulloch e Pitts

Rosenblatt criou uma rede de múltiplos neurônios do tipo *discriminadores lineares* e deu o nome a esta rede de *perceptron* (KOVÁCS, 1996).

A estrutura de rede aplicada neste trabalho é do tipo MLP, as outras classes podem ser conferidas em HAYKIN (1994) e ROJAS (1996).

A arquitetura ou topologia de uma rede neural é descrita segundo uma representação gráfica, em que se destacam os *nós*, chamados de *unidades*, *vértices* ou *neurônios* e as *conexões*, denominadas também de *pesos* ou *sinápses*.

A rede RNA definida como sendo um “... *sistema de interconexões de unidades (chamadas neurônios), baseada no sistema nervoso, que atua após um estímulo externo*” (BALLINI, 1996), representam um modelo *Markoviano*, ou seja, aquele que possui como característica a existência de equações que não possuem memória. Isto significa que a saída é função da entrada corrente e não de valores passados. (Figura 3.11)



*Figura 3.11 - Arquitetura de Rede Neural Multicamadas*

Existem várias notações para os nomes das camadas de neurônio. As classificações, de acordo com a sua posição, são:

1. Camada de entrada, é aquela cujos neurônios (unidades de entrada) propagam as informações de entrada para a camada seguinte sem que ocorram modificações;
2. Camada(s) intermediária(s) ou escondida(s), transmitem as informações, por meio das interconexões, entre as unidades de entrada e saída. Os neurônios desta camada são denominados de unidades intermediárias ou escondidas;
3. Camada de saída, cujos neurônios são denominados de unidades de saída; propagam a resposta da RNA à entrada aplicada na camada de entrada.

Neste trabalho serão adotadas as denominações seguintes tendo como o exemplo a **Figura 3.11**. A camada com as informações referentes às variáveis de entrada, será denominada

*camada de entrada*, a camada que produz a saída da rede, ou os dados calculados, é a *camada de saída* e as demais intermediárias serão as *camadas escondidas*. Outra notação topológica para uma rede totalmente conectada é feita quanto ao número de nós existentes. Por exemplo, uma rede com notação 5-3-1 ou [5,3,1], terá cinco nós de entrada (camada de entrada), três nós escondidos (camada escondida) e 1 nó de saída (camada de saída).

Seja uma rede neural artificial multicamada representada pela notação da **Figura 3.11**, o subscrito  $i$  refere-se à camada de saída da rede,  $j$  à camada escondida e  $k$  à camada de entrada.

As saídas de cada unidade são denotadas por  $A_i = a_i^p$  para a camada de saída;  $A_j$  para a camada escondida e, em se tratando da camada de entrada  $A_k = x_k^p$ . As conexões entre a camada de entrada e a camada escondida de neurônio são representadas por  $w_{jk}$  e entre a camada escondida e a camada de saída por  $w_{ij}$ . Os números de neurônios correspondentes a cada camada de entrada, escondida e de saída, são representados por  $K$ ,  $J$  e  $I$ , respectivamente.

São designados diferentes pares padrões pelo superescrito  $p$ , em que  $P$  representa o número de padrões do conjunto de treinamento -  $P(x_k, d_k)$  -,  $x_k$  é o *input* e  $d_k$  o valor desejado. Cada valor  $x_k^p$  de entrada pode ser binário ou contínuo.

### 3.4 Processo de Aprendizagem e Generalização

A propriedade de aprendizagem da rede neural é uma de suas características mais importantes. A rede aprende através de processos iterativos de ajustes aplicados sobre seus pesos e *bias*, e isto consiste basicamente na rede ser estimulada externamente, sofrer mudanças resultantes por meio desses estímulos e, finalmente, responder face às mudanças ocorridas na sua estrutura interna.

A capacidade de uma rede aprender está intrinsecamente ligada à forma de conexões entre seus neurônios, à topologia da rede, em que ambiente a rede é utilizada e no paradigma de treinamento.

Entende-se por aprendizado de rede neural, um processo em que, os parâmetros livres existentes na estrutura da rede sofrem alterações devido a uma estimulação contínua proveniente do ambiente no qual a rede está envolvida. Assim, o aprendizado se concretiza, a medida que um modelo implícito é obtido na representação de um sistema a ser simulado ou de uma tarefa a ser executada ou implementada. Isso se realiza por meio de ajustes dos respectivos parâmetros da rede.

Da **Figura 3.11**, considere  $w(t)$  um peso sináptico de um determinado neurônio num instante de tempo  $t$ . O ajuste  $\Delta w(t)$  a ser submetido ao peso  $w(t)$  nesse instante  $t$  irá gerar um novo valor corrigido, segundo a expressão:

$$w(t+1) = w(t) + \Delta w(t) \quad (3.11)$$

Mas, a obtenção do ajuste  $\Delta w(t)$  pode ser conduzida por várias técnicas, definindo nesse caso, o tipo de aprendizado a ser submetida a rede neural.

Um conjunto de regras definidas para resolver o problema de aprendizagem das redes neurais é chamado de *algoritmo de aprendizagem*. Estes algoritmos diferem uns dos outros na formulação do ajustamento dos pesos sinápticos.

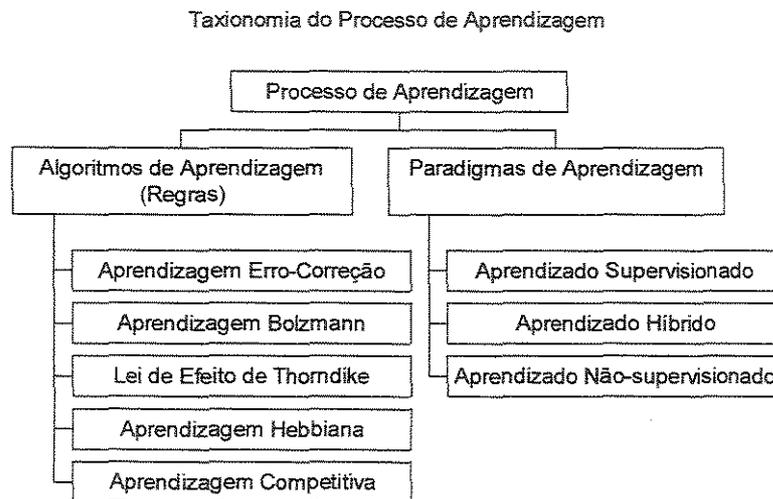
A forma particular influenciada pelo ambiente à rede durante o período de aprendizagem é denominada de *paradigma de aprendizagem*.

No aprendizado supervisionado existe um “professor”, o qual, considerando o processo de treinamento, “diz” à rede qual é a melhor performance ou o que deve ser corrigido no comportamento da rede. Existem diversos métodos de aprendizado para qualquer topologia de rede. Destacam-se: *Brain State in a Box (BSB)*, *Fuzzy Cognitive Map (FCM)*, *Boltzmann*

*Machine* (BM), *Mean Field Anneling* (MFA), *Backpropagation* (BP), *Extended Kalman Filter* (EKF), *Adaptive Logic Network* (ALN), e outros.

No aprendizado não supervisionado a rede é autônoma, ela não necessita de um “professor”. O processo é direcionado por correlações existentes nos dados de entrada: *Temporal Associative Memory* (TAM), *Kohonene Self-Organization/Topology Preserving Map* (SOM/TPM), *Discrete Hopfield* (DH), *Learning Matrix* (LM), *Optimal Linear Association Memory* (OLAM), *Couterpropagation* (CP), e outros.

O processo de aprendizagem é composto por cinco regra básicas e três classes básicas de paradigma de aprendizagem. **Figura 3.12.**



**Figura 3.12 - Taxionomia do Processo de Aprendizagem**

Fonte: HAYKIN, 1994

Neste trabalho será aplicada a rede neural um algoritmo de aprendizagem de correção do erro e paradigma supervisionado.

Considerando o uso de qualquer algoritmo ou paradigma, ao atingirmos o objetivo desejado, uma representação do conhecimento é obtida. Caso sejam seguidas algumas regras de procedimento (VON ZUBEM, 1999):

*Regra 1 – entradas similares provenientes de classes similares de fenômenos ou eventos, tendem a produzir representações similares dentro da rede, o que pode levar a classificá-la como pertencentes à mesma categoria;*

*Regra 2 – itens que devem ser classificados ou processados distintamente devem, provocar, de alguma forma, representações distintas dentro da rede;*

*Regra 3 – se uma característica é importante, então devem ser alocados recursos da rede neural (por exemplo, neurônios e conexões) para representá-la devidamente. Quanto mais complexa a representação, mais recursos devem ser alocados;*

*Regra 4- a etapa de aprendizado pode ser simplificada caso as informações conhecidas a priori e invariância sejam embutidas diretamente no projeto da rede neural.*

Na engenharia, alguns problemas podem ser solucionados por meio de aprendizado supervisionado de RNA's, tais como, classificação de padrões, previsões de séries temporais, identificação de sistemas, controle de processos e outros.

### 3.4.1 Normalização

O termo normalização é usado para representar um processo em que um vetor freqüentemente é dividido pela norma de um vetor. Outra definição encontrada na literatura refere-se ao rescalonamento<sup>14</sup> através de um mínimo ou média de um vetor, para produzir dados ou elementos que permaneçam entre o intervalo, por exemplo, de [0,1] ou [1,-1]. Este procedimento faz parte de um estágio denominado *pré-processamento* do conjunto de variáveis de entrada, neste caso, o valor da variável original é dado por  $x_k$  e após o estágio passará a valer  $\tilde{x}_k$ . O conjunto de dados de saída da rede,  $\tilde{a}_k$ , também é submetido ao estágio de *pós-processamento* para converte-los à forma numérica requerida,  $a_k$  (Figura 3. 13).

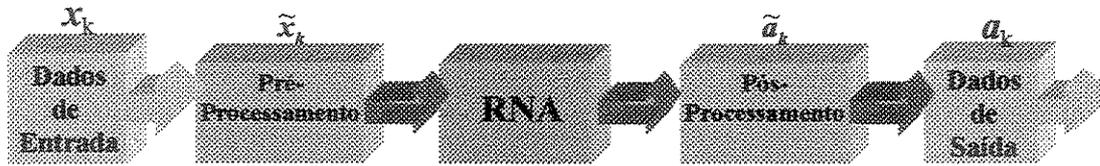


Figura 3.13 – Estágios de Pré e Pós-processamento de Rede Neural

Nas aplicações práticas a escolha do estágio de pré-processamento tem um efeito significativo sobre a performance da generalização e também pode oferecer, geralmente, grandes melhoramentos no desempenho do sistema de reconhecimento padrão (BISHOP, 1995)

Os dados de entrada de uma rede neural podem influenciar consideravelmente no processo de treinamento. O intervalo finito, o qual pertence à série de dados de entrada apresenta grande variação numérica em torno deste.

Seja uma série de dados de entrada pertencente a um intervalo fechado, apresentando grande variação, conectada a uma outra unidade ou camada. Os pesos correspondentes a estas conexões, serão ajustados pelo processo de treinamento da rede e esta adaptação dinâmica poderá demandar um maior gasto de tempo computacional devido a essa variação (BISHOP, 1995).

A solução desse problema é aplicar a normalização, que consiste basicamente, em transformar linearmente os pares padrões. Após o treinamento; os resultados calculados pela rede passam por um processo de reversão da normalização para os valores reais.

Dentre os vários procedimentos de normalização requeridos pelas funções de ativação não lineares, como exemplo, aplicando a equação (3.11) os valores normalizados estarão no intervalo de  $[0,1]$  ou  $[1,-1]$ .

$$\tilde{x} = \frac{(x - x_{\min, \text{exp}}) \cdot (x'_{\max} - x'_{\min})}{x_{\max, \text{exp}} - x_{\min, \text{exp}}} + x'_{\min} \quad (3.12)$$

<sup>14</sup> Defini-se como adicionar ou subtrair a um vetor, uma constante e, a seguir, multiplicar ou dividir por uma

no qual,  $x$  é do valor da variável,  $\tilde{x}$  é um valor da variável normalizado,  $x_{\max, \text{exp}}$  é o valor máximo da variável,  $x_{\min, \text{exp}}$  é o valor mínimo da variável,  $x'_{\max}$  é o valor máximo da variável normalizada e  $x'_{\min}$  é o valor mínimo da variável normalizada. Caso a função de ativação escolhida para o treinamento da rede seja a *tangente hiperbólica*, o intervalo de escolha de  $x'_{\min}$  e  $x'_{\max}$ , poderá ser  $[-1, 1]$ .

### 3.4.2 *Aprendizado Supervisionado*

A RNA possui a habilidade de aprender, ou seja, por meio de treinamento a rede tem a possibilidade de computar, sem que haja a necessidade de se especificar todos os detalhes desta computação. Neste modelo é empregado um aprendizado<sup>15</sup> supervisionado, no qual as entradas e suas respectivas saídas (conjunto de treinamento) são apresentadas simultaneamente à rede, em cada iteração do processo de treinamento. A rede calcula o erro entre o padrão de saída desejado e o obtido naquela iteração, o erro gerado é propagado através da rede. Os pesos das sinapses são atualizados através da aplicação de um determinado algoritmo que conseqüentemente minimize este erro. Este procedimento é feito até que o valor do erro encontrado para o vetor de treinamento seja o menor possível. Este é o tipo de treinamento usado no algoritmo de retropropagação (*Backforward*). **Figura 3.14.**

---

constante – mudança de unidade de medida de um dado, por exemplo, passar da unidade de temperatura grau Celsius (°C) para grau Kelvin (°K).

<sup>15</sup> Aprendizado é definido com sendo a modificação realizada na matriz dos pesos  $w$  de uma rede, no sentido de otimizar um mapeamento dos padrões de entrada e saída. (LIMA, 1996).

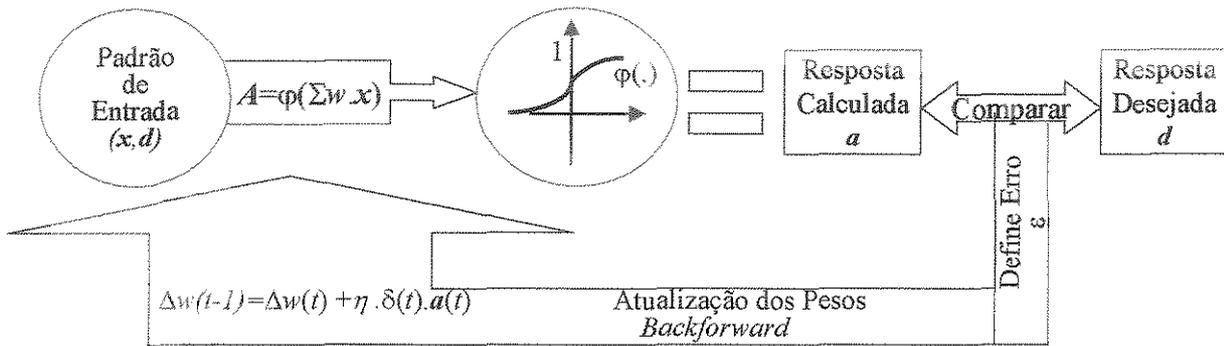


Figura 3.14 – Treinamento Supervisionado de uma RNA

### 3.4.3 Regra de Aprendizagem de Correção do Erro

O primeiro processo de treinamento para rede neural linear - ADALINE (*Adaptive Liner Element*), conhecido como *Regra Delta* ou *Método do Gradiente*, foi criado por B. Widrow. Tinha como proposta, calcular o ponto de mínimo por meio de um processo de iteração local, utilizando um exemplo do conjunto de treinamento por vez (KOVÁCS, 1996).

No treinamento de rede RMC, um dos algoritmos de 1ª ordem mais utilizados é o *Backpropagation* – BP, (ou da Retropropagação do Sinal do Erro) – Figura 3.15. Possui como forma de atualização (ajustamento) dos pesos a *Regra Delta Generalizada* (RDG), criada por D.E. Rummelhart, G.E. Hinton e R.J. Williams, que implementam o método do gradiente simples. Esta regra, teve como origem a *Regra Delta* de Widrow ou *Regra de Aprendizagem de Correção do Erro* (*Error-Correction Learning*) e a diferença está na inclusão de um parâmetro constante denominado de *momentum* ( $\alpha$ ), que geralmente é número positivo. A RDG consiste em ajustar os pesos sinápticos para um intervalo de tempo.

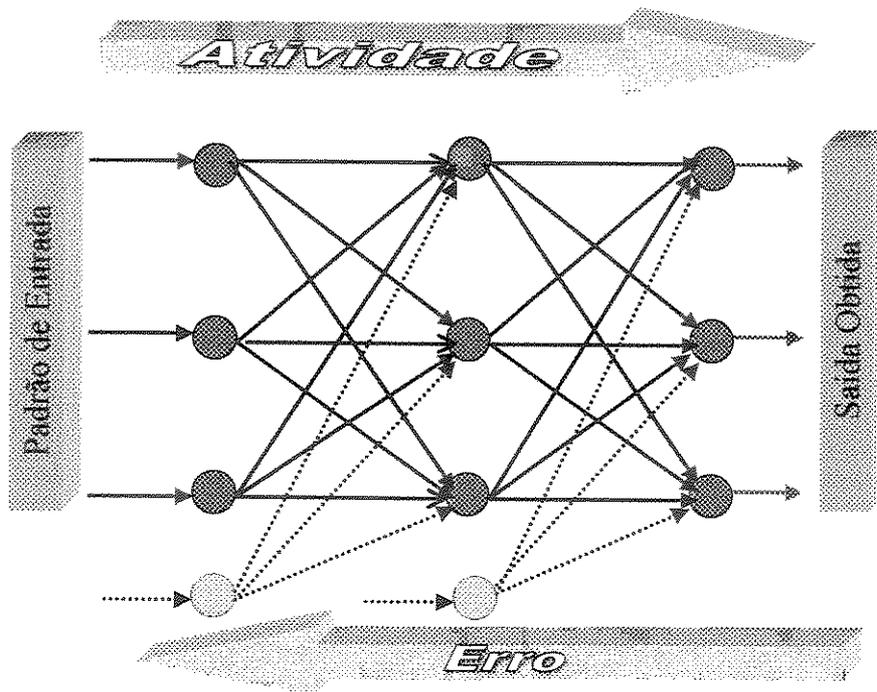
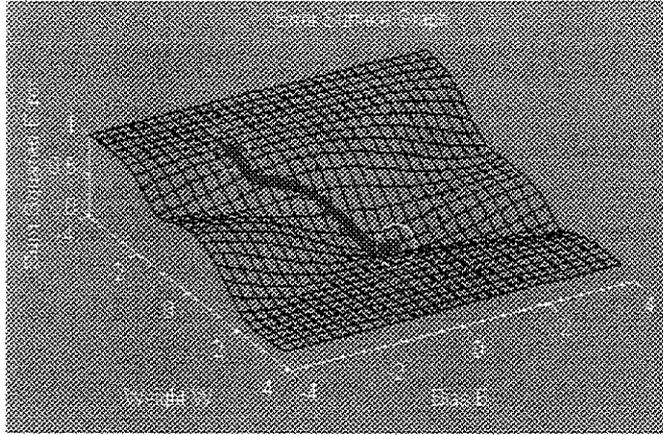


Figura 3.15 – Direções de Propagações do Sinal Funcional e do Erro

A adição do *momentum* na regra de aprendizagem resulta em uma rede com menor sensibilidade às características locais da superfície de erro e maior sensibilidade às grandes tendências. Tal rede pode “escapar” de superfícies mínimas locais.

A plotagem da função custo (nesse exemplo, Soma do Erro Quadrático – *Sum Squared Error*) versus os pesos sinápticos e *bias*, caracterizando desta forma uma rede neural, consiste em uma superfície multidimensional denominada *superfície da performance do erro* ou, simplesmente, *superfície de erro (Error Surface)* – Figura 3.16.



*Figura 3.16 – Superfície de Erro*

Considerando que a rede neural consiste em unidade de processamento não linear, a superfície de erro consistirá de um mínimo global ou, até mesmo vários mínimos locais.

O processo matemático de treinamento da rede é realizado da seguinte maneira: para cada padrão apresentado à rede ( $x_k^p$ ), a camada escondida calcula a soma ponderada das unidades da camada de entrada conectada a ela:

$$n_j^p = \left( \sum_{k=1}^K w_{jk} \cdot x_k^p \right) - \theta_j \quad (3.12)$$

que será o argumento da função de ativação,  $\varphi(\cdot)$ , resultando a saída

$$A_j^p = \varphi(n_j^p) \quad (3.13)$$

Cada neurônio de saída  $i$ , receberá os sinais  $A_j^p$  de cada unidade escondida e calculará:

$$n_i^p = \left( \sum_{j=1}^J w_{ij} \cdot A_j^p \right) - \theta_i \quad (3.14)$$

em que a partir desse resultado será calculada a saída da rede por:

$$a_i^p = A_i^p = \varphi(n_i^p) \quad (3.15)$$

sendo que  $\varphi(\cdot)$  é a função de ativação para cada unidade da rede e  $\theta$  são os respectivos limiares.

Seja  $d_i(t)$  representado pelo valor desejado ou resposta meta para um neurônio  $i$  em um tempo  $t$  de uma rede neural multicamada e o valor calculado por ela representado por  $a_i(t)$ , correspondente ao estímulo aplicado pelo vetor input  $x_R(t)$ .

Como o valor da resposta calculada é diferente do valor desejado, então é embutido um erro entre as diferenças desses valores. O sinal do erro na saída do neurônio  $i$  após a  $t$ -ésima iteração, é definido como:

$$\varepsilon_i(t) = d_i(t) - a_i(t) \quad (3.16)$$

O valor instantâneo da soma dos erros médio quadrático sobre todos os neurônios da camada de saída, por definição é dado pela expressão:

$$E(t) = \frac{1}{2} \sum_{i \in C} \varepsilon_i^2(t) \quad (3.17)$$

onde  $C$  corresponde ao conjunto de todos os neurônio a na camada de saída da rede. O *Erro Médio Quadrático (Mean Squared Error - MSE)*, é obtido pelo somatório de  $E(t)$  e então normalizando com relação ao conjunto de tamanho  $N$  (número de padrões apresentados), dado pela expressão:

$$E(W) = \frac{1}{N} \sum_{t=1}^N E(t) \quad (3.18)$$

O objetivo da aprendizagem por correção do erro é minimizar a função custo ou função aproximada  $E(W)$  com relação aos pesos sinápticos da rede, que é uma medida sobre o erro  $\varepsilon_k(t)$ , de maneira que o valor de  $a_i(t)$  se aproxime o máximo possível do valor de  $d_i(t)$ . A função custo

comumente usada é a do *MSE*, do tipo contínua e diferenciável para qualquer peso sendo representada pela expressão (3.18). Pode ser considerado outro tipo de função, por exemplo, a do *Desvio Médio Absoluto (Mean Absolute Deviation - MAD)*<sup>16</sup>, ou ainda, a *Soma dos Erros Quadráticos (Sum Squared Error - SSE)*. Esta minimização da função MSE com relação aos parâmetros da rede conduz ao *método do gradiente descendente*, que consiste em dada uma medida de erro ou função custo representado por  $E(W)$ , buscar o melhor conjunto de pesos  $W_{ji}$  deslizando no sentido descendente da superfície definida no espaço  $W$ , ou seja, tenta minimizar a função (ABELÉM, 1994).

Um dos problemas de aproximação paramétrica, incide em uma questão bem natural: como escolher a função de aproximação que melhor ajuste, ou seja, que tipo de restrição paramétrica deve ser imposta ao modelo de aproximação (VON ZUBEN, 1996).

O ajustamento ou correção dos pesos é feito a partir do valor do erro calculado para cada padrão de treinamento apresentado à rede. O nível de atividade interna da rede  $n_i(t)$  produz uma entrada de não linearidade associada com o neurônio  $i$  e tem a seguinte expressão:

$$n_i(t) = \sum_{j=0}^P w_{ji}(t) a_j(t) \quad (3.18)$$

no qual  $P$  o número total de entradas (exceto os limiares) aplicada ao neurônio  $i$ . Logo o valor calculado na saída do neurônio  $i$  é:

$$a_i(t) = \varphi_i(n_i(t)) \quad (3.19)$$

no qual  $\varphi(\cdot)$  é a *Função de Ativação*.

A *Função de Ativação (FA)*, representa o efeito que a entrada interna e o estado atual de ativação exercem na definição do próximo estado de ativação da unidade. O emprego da FA nas camadas intermediárias de uma rede neural se faz pela necessidade de se introduzir a não

---

<sup>16</sup> A vantagem que MAD exerce sobre MSE é que trata os erros de maneira igual, enquanto a outra, penaliza-os de maneira mais rigorosa elevando-os ao quadrado.

linearidade (capacidade de representar função não linear), isto é, sem a não linearidade, as camadas escondidas não se tornariam mais poderosas que os *perceptrons* planos. Estes, por sua vez, não possuem camadas escondidas, apenas constituem-se de camadas de entrada e saída. A não linearidade é uma das grandes características potenciais da RMC (funções do tipo *sigmoid* são recomendáveis).

Com relação a camada de saída, a escolha da FA deverá habilitar uma distribuição dos valores meta ou desejados. As funções do tipo *sigmoid*, são comumente usadas quando a série meta é limitada. Quando estes valores não são limitados, é necessário o uso de FA não limitada (Função identidade) (JORDAN, 1995).

Uma das características requerida para uma FA é que ela satisfaça a propriedade de existência da derivada, devido à necessidade de o cálculo do gradiente local de cada neurônio de uma RMC requerer o conhecimento da derivada de FA. Quando as propriedades dinâmicas estão envolvidas na definição do estado de ativação, são então empregados alguns tipos de função com características monotonicamente não decrescente, que defina o estado e ativação. Um exemplo de FA não linear diferenciável continuamente, mais aplicada em redes do tipo RMC é *sigmoidal não linear*. Uma forma particular definida para um neurônio  $i$  é pela *função logística (logistic function)*,

$$\varphi_i(n_i(t)) = \frac{1}{1 + \exp(-n_i(t))}, \quad -\infty < n_i(t) < \infty \quad (3.20)$$

na qual  $n_i(t)$  é o nível atividade interna do neurônio  $i$ . De acordo com a linearidade, a amplitude da saída permanece no intervalo de  $0 \leq n_i \leq 1$ .

Outro tipo de não linearidade *sigmoidal* é a função *tangente hiperbólica*, a qual assume a forma assimétrica com relação a origem e para qual a amplitude da saída permanece no intervalo de  $-1 \leq n_i \leq 1$ , representada pela equação (HAYKIN, 1994):

$$\varphi(n_i(t)) = a \tanh(bn) \quad (3.21)$$

onde  $a$  e  $b$  são constante.

No caso particular do algoritmo BP aplica a correção  $\Delta w_{ij}(t)$  para o peso sináptico  $w_{ij}(t)$ , que é proporcional ao gradiente<sup>17</sup>  $\frac{\partial E(t)}{\partial w_{ij}(t)}$ . De acordo com a *Regra da Cadeia*, o gradiente é expresso por:

$$\frac{\partial E(t)}{\partial w_{ij}(t)} = \varepsilon_i(t) \varphi'_i(n_i(t)) a_i(t) \quad (3.22)$$

A correção  $\Delta w_{ij}(t)$  aplicada ao peso  $w_{ij}(t)$  é definida pela *Regra Delta*

$$\Delta W_{ij}(t) = \eta \left( \frac{\partial E(t)}{\partial W_{ij}(t)} \right) \quad (3.23)$$

em que  $\eta$  é um parâmetro constante chamado de *taxa de aprendizagem* do algoritmo BP, o subscrito  $i$  é o neurônio  $i$  da camada posterior e o subscrito  $j$  é o neurônio  $j$  da camada anterior. O algoritmo de retropropagação do erro (método de obtenção das derivadas parciais) é conhecido por *Backpropation Padrão*. Nele a regra da cadeia irá propagar a função  $E(W)$  definida na saída da rede, via caminho inverso, seguindo até a entrada da rede.

Outra forma de se representar à correção do peso é dada pela fórmula:

$$\Delta w_{ij}(t) = \eta \delta_i(t) a_i(t) \quad (3.24)$$

sendo  $\delta_i(t)$  o gradiente local para o neurônio de saída  $i$  e definido como o produto do erro correspondente ( $\varepsilon_i(t)$ ) pela derivada  $\varphi'_i(n_i(t))$  da função de ativação associada.

Dependendo de onde o neurônio  $i$  está localizado, pode-se definir dois casos para o cálculo da correção do erro, segundo o valor do gradiente local  $\delta_i(t)$ :

- Caso 1: Neurônio  $i$  está na camada de saída. Neste caso existe um valor meta a ser comparado e, calculado o erro  $\varepsilon_i(t)$ , a expressão que determina o gradiente local  $\delta_i(t)$  é dada por:

$$\delta_i(t) = \varepsilon_i(t) (\varphi_i'(t)) \quad (3.25)$$

- Caso 2: O neurônio  $i$  está na camada intermediária. Neste caso não existe um valor meta para comparações e a expressão do gradiente local é redefinida por:

$$\delta_i(t) = (\varphi_i'(t)) \sum_K \delta_k(t) w_{kj}(t) \quad (3.26)$$

Resumindo, a *Regra Delta* é definida pela correção  $\Delta w_{ij}(t)$  aplicada aos pesos sinápticos conectando o neurônio  $j$  ao neurônio  $i$ ,

$$\begin{bmatrix} \text{Correção} \\ \text{do Peso} \\ \Delta w_{ij}(t) \end{bmatrix} = \begin{bmatrix} \text{Parâmetro} \\ \text{Taxa de} \\ \text{Aprendizagem} \\ \eta \end{bmatrix} \times \begin{bmatrix} \text{Gradiente} \\ \text{Local} \\ \delta_i(t) \end{bmatrix} \times \begin{bmatrix} \text{Entrada no} \\ \text{Neurônio } i \\ a_i(t) \end{bmatrix}$$

Ao ser atribuído um dado valor à *taxa de aprendizagem*  $\eta$  observa-se que se este valor é muito pequeno a velocidade de aprendizagem da rede torna-se lenta, pois são bem menores as mudanças em  $w_{ij}$ . No caso de  $\eta$  ser grande, implica em velocidades de aprendizagens rápidas e, as mudanças dos pesos sinápticos serão grandes. Um dos mecanismos bastante utilizado para corrigir estas distorções (instabilidade na rede, ou seja, movimentos oscilatórios) é o método modificado

<sup>17</sup> O gradiente representa o fator sensitivo, o qual determina a direção de busca dentro do espaço para o peso sináptico  $w_{ij}$ .

da *Regra Delta*, o qual inclui o termo *momentum*<sup>18</sup> e que é chamado de *Regra Delta Generalizada* (RDG). A correção do peso é então dada por:

$$\Delta w_{ij}(t) = \alpha \Delta w_{ij}(t-1) + \eta \delta_i(t) a_j(t) \quad (3.26)$$

sendo  $\alpha$  a constante *momentum*, geralmente um número positivo ( $0 \leq |\alpha| < 1$ ) que controla o *loop* de realimentação em torno de  $\Delta w_{ij}(t)$ . Quando  $\alpha$  é igual a um, o algoritmo BP opera sem a constante *momentum*.

A inclusão da constante  $\alpha$  no BP tende a implementar uma aceleração descendente sob direção do valor estacionário. Possui, também, um efeito estabilizador nas direções que oscilam.

Muitos são os algoritmos usados nos treinamentos de RNA's, e alguns são baseados no algoritmo proposto por D.O.Hebb em 1961. Já os mais eficientes são baseados em trabalhos publicados por Widrow em 1959, Widrow e Hoff no ano de 1960 e Rosenblatt em 1962. Indiscutivelmente, o mais utilizado em redes multicamadas e difundido na literatura é o algoritmo de retropropagação do erro ou *backpropagation*, apresentado no Apêndice A.

#### 3.4.4 Modos de Treinamento de RMC

Na prática, os resultados de uma simulação decorrente do treinamento da rede por meio do algoritmo *backpropagation* resultam de várias apresentações de um conjunto de exemplos de treinamento inicialmente adotados (par padrão). Quando a apresentação se dá utilizando todo o conjunto de treinamento durante um processo de aprendizagem denomina-se *época* (*epoch*).

O processo de aprendizagem é conduzido época-por-época até que os pesos sinápticos e os níveis de limiares (*threshold* ou *bias*) da rede encontrem a estabilização, simultaneamente

---

<sup>18</sup> É um termo de incremento a retropropagação, de tal forma que, sua finalidade é fazer escapar a busca dos mínimos locais.

convergindo a um valor mínimo do erro, considerando aquele conjunto de treinamento selecionado.

Utilizando um processo iterativo, existem dois tipos possíveis de métodos de treinamento para se calcular a atualização dos pesos em algoritmos de aprendizagem de RMC a partir de um conjunto de dados para treinamento da rede. Estes algoritmos apresentam-se como (SILVA, 1998):

1. Método em Lote (Batelada ou *Batch* ou *Off-line*): este tipo apresenta apenas uma correção dos pesos por ciclo (época), ou seja, no treinamento os parâmetros são atualizados logo após a apresentação de toda as amostras à rede, conforme o algoritmo:

- Defina uma condição de iniciar  $w(0)$  para o vetor de parâmetros;
- Atribua um valor fixo para o tamanho do passo  $\delta$  e defina um escalar  $\varepsilon > 0$ , arbitrariamente pequeno;
- Faça  $t=0$  e calcule  $E(W(t))$ ;
- Enquanto  $\sqrt{2 E(W(t)) / N} \geq \varepsilon$ , faça

✓ Para  $1 < l < N$ , faça:

Calcule  $\nabla E_l(W(t))$ ;

$$✓ \quad W(t+1) = W(t) - \frac{\eta}{N} \sum_{l=1}^N E_l(W(t));$$

✓  $t = t + 1$ ;

✓ Calcule  $E(W(t))$ .

em que  $N$  é o número de amostras ou padrão de treinamento, e  $\eta$  é a taxa de aprendizagem da rede.

2. Método Padrão-a-Padrão (*Pattern Mode* ou *On-line*): este tipo atualiza os pesos após cada apresentação do par padrão (saída/entrada) do conjunto de treinamento. O método resume-se no seguinte procedimento:

- Defina uma condição inicial  $w(0)$  para o vetor de parâmetros;
- Defina um escalar  $\varepsilon > 0$  arbitrariamente pequeno,  $0 < r < 1$  e  $q > 1$ ;
- Faça  $t = 0$  e  $\delta = 1$ , calcule  $E(W(t))$ ;
- Enquanto  $\sqrt{2 E(W(t)) / N} \geq \varepsilon$ , faça
  - ✓ Ordene aleatoriamente os padrões de entrada-saída;
  - ✓ Calcule  $l$  variando de 1 até  $N$ , faça:

Calcule  $\nabla E_l(W(t))$ ;

$$W^{prov}(t+1) = W(t) - \eta \frac{\nabla E_l(W(t))}{\|\nabla W_l(W(t))\|};$$

Enquanto  $E(W^{prov}(t+1)) \geq E(W(t))$ , faça;

$$\delta = r \cdot \delta;$$

$$W^{prov}(t+1) = W(t) - \eta \frac{\nabla E_l(W(t))}{\|\nabla W_l(W(t))\|};$$

$$W(t+1) = W^{prov}(t+1);$$

$$\delta = q \cdot \delta;$$

$$t = t + 1;$$

Calcule  $E(W(t))$ .

Do ponto de vista operacional, a vantagem que o modo padrão exerce sobre o modo em batelada é devido àquele requerer menos armazenagem local para cada conexão sináptica (PARMA, MENEZES e BRAGA, 1997). Porém a eficiência de cada um dependerá do problema em questão.

### 3.4.5 Inicialização dos Pesos

A *inicialização dos pesos* de uma rede neural é um dos fatores relevantes com vista ao melhor ajuste dos pesos sinápticos e limiares decorrentes do treinamento por retropropagação do erro. Uma escolha inicial errada dos parâmetros livres pode levar a rede a um fenômeno conhecido como *saturação prematura* (*premature saturation*) (LEE et al, 1991). Este fenômeno refere-se a um determinado procedimento que ocorre durante o treinamento da rede, em que o erro médio quadrático permanece quase constante por alguns períodos de tempo durante o processo de aprendizagem da rede, com isso, mascarando a existência do erro mínimo. Neste caso, o processo de aprendizagem pode ser interrompido impedindo a busca do provável erro mínimo da função fazendo com que a convergência ocorra prematuramente. (Figuras 3.17 e 3.18).

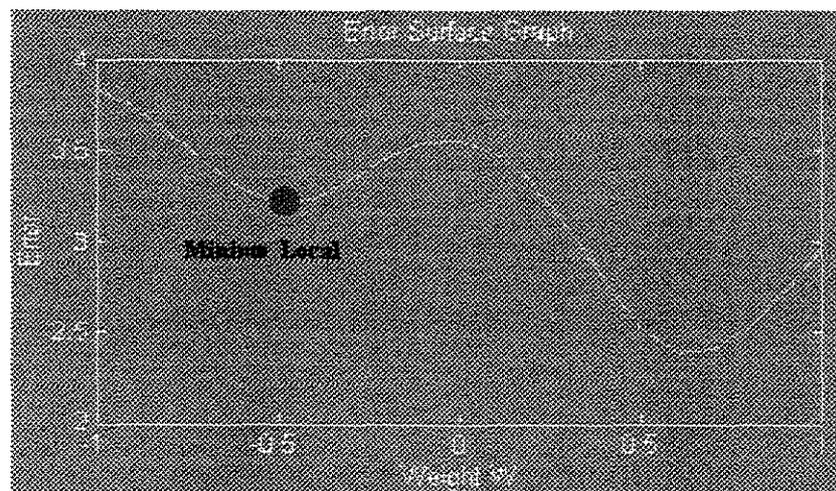
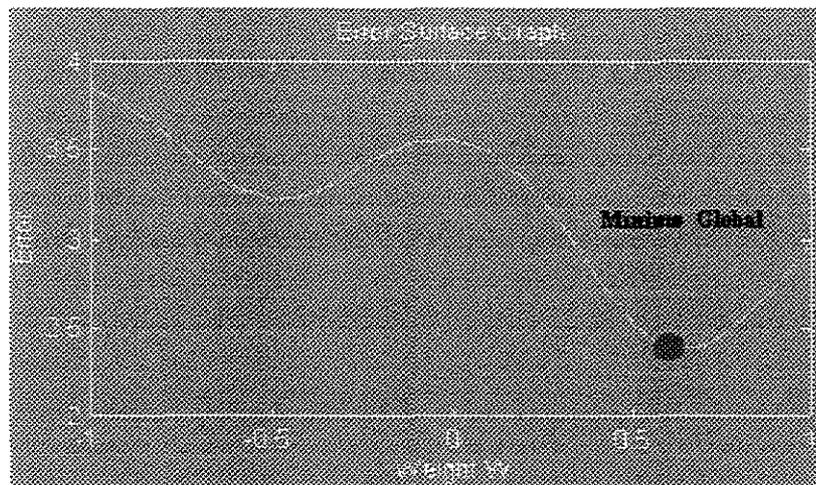


Figura 3.17 – Superfície de Erro – Mínimo Local



*Figura 3.18 – Superfície de Erro - Mínimo Global*

Melhoramentos nos algoritmos de treinamento e topologia ótima da rede, apesar de serem uma boa estratégia de acertos voltada a inicialização dos pesos, não garantem boa convergência da rede se os pesos forem mal inicializados. Um dos procedimentos de obtenção de resultados mais rápidos e precisos pode ser realizado quando o ponto de partida do processo de otimização estiver o mais próximo da solução ótima.

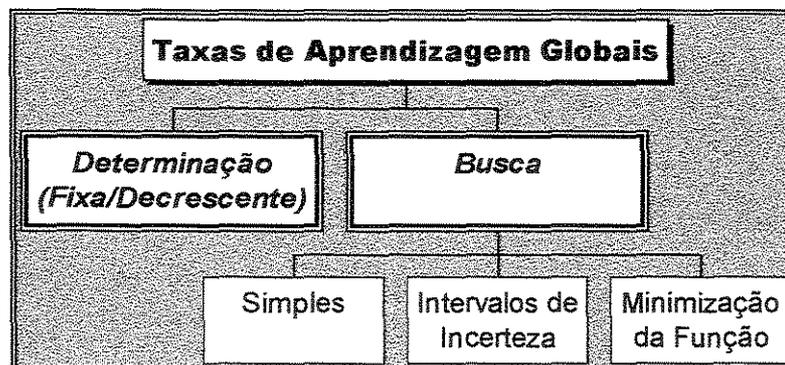
Uma regra muito utilizada baseia-se em inicializar uma rede com pesos aleatórios numericamente pequenos. A motivação para este procedimento é que valores absolutos muito grandes de pesos originam nós escondidos a serem altamente ativos ou inativos para toda a amostra de treinamento e, então, indiferentes para o processo de treinamento. Outro processo recomendado de inicialização não-aleatória é linearizar a rede, e então calcular os pesos iniciais por meio de regressão linear. Esta estratégia torna-se vantajosa se o problema for mais ou menos linear, então, a maior parte do treinamento é feita antes do ajustamento iterativo dos pesos ser iniciado. (LEONDES, 1998).

### 3.4.6 Taxa de Aprendizagem

A *Taxa de Aprendizagem* ou tamanho do passo de treinamento ( $\eta$ ) na direção do ponto mínimo de uma função custo é o parâmetro aplicado no algoritmo de retropropagação do erro. Podendo assumir um único valor, quando o treinamento for submetido a forma em batelada ou vários valores, quando a forma de treinamento for do tipo padrão.

No caso de um único valor para a taxa, multiplica-se a direção do ajuste escalar, neste caso, sem alteração da direção indicada pelo ajuste. Para a outra situação, em que se admite mais de um passo de ajuste, o procedimento indica multiplicar a direção do ajuste por uma matriz, neste caso, a direção de ajuste será modificada e escalonada.

Alguns tipos de taxa de aprendizagem globais são empregados no ajuste dos vetores do parâmetro peso (**Figura 3.19**).



*Figura 3.19 – Taxas de Aprendizagem Globais*

No cálculo fixo da taxa, assume-se que os padrões de treinamento em lote, por serem semelhantes, irão produzir gradientes semelhantes. Logo, o conjunto de treinamento deverá ser dividido em  $n$  subconjuntos de amostras similares, com dimensão  $(x_1, x_2, \dots, x_n)$ , de tal forma que, quanto menor  $n$ , menor será  $\eta$ .

Na atualização realizada após cada par padrão, é aplicada uma taxa de aprendizagem decrescente, em que  $\eta$  diminui durante o treinamento. Esses métodos, embora bastantes simples,

não garantem a minimização dos passos, apenas os métodos de busca unidimensionais ou métodos de busca, garantem uma boa minimização a cada interação – apesar de demandarem muito tempo no processo computacional.

O método de busca fixa, não conduz a um valor ótimo para o passo  $\eta$ . Ele limita-se a avaliar a função, caso ocorra a redução no erro, na primeira tentativa.

Os métodos que atribuem um intervalo de incerteza, no qual possa estar inserido o valor ótimo para  $\eta$ , são *Método de Fibonacci* e *Método da Seção Áurea*, que utilizam busca unidirecional sem a utilização da derivada da função custo e, o *Método da Falsa Seção* que precede a busca utilizando a derivada. Outra diferença verificada entre essas técnicas, indica que as duas primeiras trabalham com a concepção da diminuição do intervalo de incerteza, enquanto a outra, minimiza a função  $\phi(\cdot)$ . SILVA (1998) descreve os respectivos algoritmos para as três técnicas de determinação da taxa de aprendizagem.

### 3.4.7 Critério de Parada

Um dos critérios de parada geralmente atribuídos à convergência da rede, é o de interromper o processo iterativo do treinamento, limitado por uma quantidade ou número de interações pré-definidos. Outros critérios são observados por HAYKIN (1994):

•É considerado que o algoritmo de retropropagação convergiu quando a norma Euclidiana da estimativa do vetor gradiente atingiu um valor suficientemente pequeno;

•É considerado que o algoritmo de retropropagação convergiu quando a variação de erro quadrático de uma época (ou passo) para outra, atingiu um valor suficientemente pequeno;

•É considerado que o algoritmo de retropropagação convergiu quando o erro quadrático médio atingir um valor consideravelmente pequeno, ou seja,  $E_{med}(\mathbf{x}) \leq \epsilon$ , em que  $\epsilon$  é um valor suficientemente pequeno.

É importante observar que se for considerado como critério de parada, o valor mínimo para a função custo, torna-se difícil garantir a convergência do algoritmo ao valor desejado, ou seja, uma hipótese é que o valor  $\epsilon$  desejado pode ser menor que o valor mínimo da função.

Uma alternativa para melhorar a convergência da RMC é incrementar as funções custos de modo que sua capacidade esteja voltada a “escapar” dos mínimos locais.

### 3.4.8 *Validação Cruzada*

A validação cruzada ou *cross validation* é uma técnica usada para auxiliar a determinação dos valores ótimos de alguns parâmetros livres, que não possuem regras para determiná-los e que são usados em RMC e no algoritmo BP. Esses procedimentos, indicam a ocorrência de *overtraining* ou treinamento executado de forma excessiva, como também, interrompimento do treinamento antes de encontrar o valor mínimo do erro.

As deduções da dimensão da rede e dos valores dos pesos são as alternativas indicadas por SARLE (1995) e PRECHELT (1997), na solução do *overtraining* da rede. Técnicas utilizadas na redução do tamanho da rede são empregadas através dos métodos construtivos ou do método de poda. Na tentativa de reduzir a dimensão de cada parâmetro à técnica empregada é a regularização ou procedimentos de validação cruzada.

A validação cruzada consiste em dividir o conjunto de treinamentos em dois ou três subconjuntos distintos. A técnica básica é:

1. Um subconjunto usado para treinamento da rede, denominado de subconjunto de treinamento. É usado para ajuste dos parâmetros (pesos). Um subconjunto usado na validação, denominado de subconjunto de validação e um terceiro subconjunto usado para o teste da rede. Este subconjunto é aplicado somente para avaliar a performance (generalização) de toda a rede especificada;
2. Proceda ao treinamento para o conjunto selecionado e verifique o erro encontrado no subconjunto de validação em cada interação processada;

3. Caso o erro do conjunto de validação na iteração  $i$  superar o da iteração precedente, interrompa o treinamento;
4. Empregue o conjunto de pesos anteriores, como resultado do treinamento e;
5. O conjunto de dados para este peso, só será empregado se a série for extensa.

Não há uma rigidez atribuída a divisão dos conjuntos de dados, com vistas a atender uma melhor generalização dos casos. Mas HAYKIN (1994), admite a seguinte partição, a ser aplicada aos respectivos subconjuntos de dados: 50% da série dos dados para o subconjunto de treinamento, 35% para o subconjunto de validação e o restante para o teste da rede. Caso a série seja pequena, caberá entre 10 a 20% do tamanho da série para o subconjunto de validação e o restante para o treinamento, dispensando o subconjunto de teste.

O subconjunto de validação é proposto para que seja verificado ou avaliado o desempenho da rede, ao passo que, na escolha de mais um subconjunto, sendo este o de teste, a utilidade recai em uma avaliação do desempenho da rede, a partir do instante em que esta entra em operação.

### **3.4.9**     *Generalização*

A escolha do conjunto de treinamento de RNA é considerada o principal fator na determinação de uma generalização ótima, pois deve traduzir as características gerais do universo considerado.

Dentre as habilidades da rede, a que mais se destaca é a de máxima aproximação dos valores calculados por ela, daqueles desejados, a partir de uma série de dados de entrada treinados. Mas a proposta que viabiliza ou mede a capacidade de simulação de uma rede é a generalização, ou seja, para que valores calculados pela rede se aproximem dos valores metas, o

conjunto de dados de entrada não é o mesmo conjunto de treinamento, outra série de dados deverá ser usada, neste caso, a série de teste.

Nem sempre é possível ocorrer uma boa generalização. Existem três condições necessárias, embora não suficientes, para que ela ocorra (CAUDILL e BUTLER, 1990):

1. *Condição 1*: que os dados de entrada da rede contenham informações suficientes, os quais estejam relacionados com os dados de saída, isto é, que exista uma perfeita relação funcional matemática da saída para a entrada, com grau suficiente de acuracidade;
2. *Condição 2*: que a função usada no treinamento de uma aprendizagem, a qual relaciona entradas para saídas corretas, seja, num certo sentido, suave – uma mudança pequena nas entradas, na maioria das vezes, produz pequenas mudanças nas saídas;
3. *Condição 3*: que os casos (amostras – significado estatístico) de treinamento sejam um subconjunto suficientemente grande e representativo do conjunto de todos os casos que se deseja generalizar (população – significado estatístico). Sob estas condições e dentro de um treinamento apropriado, a rede neural será capaz de generalizar com certa segurança aquela população.

### 3.5 Simuladores de RNA's

Simuladores são aplicativos computacionais que simulam o processo de treinamento de redes neurais artificiais, utilizando diversos métodos de otimização não linear. Esses programas computacionais estão disponíveis na Internet através do seu respectivo *site*, porém alguns deles são de uso livre (*freeware*). No **Quadro 3.3** apresentam-se alguns simuladores, nos quais identifica-se a empresa distribuidora do software e para aqueles que podem ser feito o *download*, consta o endereço da página na Web. Também estão registradas as capacidades básicas de cada aplicativo bem como o sistema operacional requisitado.

NOME	EMPRESA	CAPACIDADES BÁSICAS	SISTEMA OPERACIONAL
1 BramMatat	California Scientific Software	Treinamento de RNA	Windows, Mac
2 SAS Enterprise Miner Software	SAS Institute, Inc	Treinamento de RNA	Windows NT
3 NeuralWorks Professional II Plus	NeuralWare Inc	Suporte por 30 tipos de RNA diferentes	PC, Sun, IBM R5600, Mac, SGI, HP
4 MATLAB Neural Network Toolbox	The MathWorks, Inc	Várias funções para treinamento de RNA	PC, Mac, Sun
5 Propagator	ARD Corporation	Pacote de treinamento de RNA	Sun, PC, Mac
6 NeuroForecaster(TM)/Genetica 4.1a	Accel Infotech	Previsão de séries temporais, previsão de sistemas de suporte a decisão, modelos de redes Neuro-fuzzy	
7 NeuroShell2/NeuroWindows	Ward Systems Group, Inc	Treinamento de RNA	PC
8 Neuralyst Version 1.4	Cheshire Engineering Corporation	Treinamento de redes com o algoritmo BP	PC, Mac
9 NeuFuz4	National Semiconductor Corporation	Técnica de BP associada a lógica Fuzzy	Windows
10 NeuroSolutions v3.0	NeuroDimension, Inc	Simulador gráfico de RNA	Windows 95/98 e Windows NT
11 One! For Windows Version 2.0	Vesta Services, Inc	Treinamento de RNA	Windows NT, 95
12 NeuroLab, A Neural Network Library	Mikumi Berkeley R & D Corporation	Treinamento de RNA	Mac, Windows
13 NeuroGenetic Optimizer (NGO) Version 2.0	BioComp's Systems, Inc	Utiliza algoritmos genéticos na otimização de RNA	Windows
14 Neuro Connection	SPSS Inc.	Previsão e modelagem de séries temporais aplicando RNA	Windows 3.1/95
15 Neural Bench	Neural Bench Development	Simuladoras de RNA	Windows 3.x/95/NT
16 Trajan 2.0 Neural Network Simulator	Trajan Software Ltd	Treinamento de RNA	Windows 95/NT
17 DataEngine, DataEngine_ADL, DataEngine V.	MIT, GmbH	Análise de dados implementando sistemas baseados em Regra Fuzzy, métodos Fuzzy-Cluster, RNA e sistemas Neuro-Fuzzy	Windows
18 STATISTICA: Neural Networks	StatSoft, Inc.	Treinamento de RNA, Algoritmos Genéticos	Windows
19 BioNet Simulator	NCSS - Development Ltd	Treinamento de RNA	Windows 95/NT
20 Rochester Connectionist Simulator	ftp.cs.rochester.edu	Programa simulador de varios tipos de RNA	
21 NeurDS	http://hpux-ci.szu.se.jp/hipd/hpux/NeuralNet/NeurDS-51/	Simulador de sistemas neurais	Windows
22 GENESIS 2.0	ftp://genesis.bbb.caltech.edu/pub/genesis	Simulador de RNA	UNIX
23 Mchvatron	ftp.cs.colorado.edu	Simulador de RNA	Mac
24 SNNS 4.1	http://www-ra.informatik.uni-tuebingen.de/SNNS	Treinamento de RNA com interface gráfica 2D e 3D	SunOs, IRIX, OSF, AIX, HP/UX, Linux, Windows 95/NT, NextStep
25 Aspinio/MICRAINES 6.0	ftp.segnet.tiella.edu [128.97.50.19] sim/pub/alexis/am6.tar.Z	Simulador de RNA	Windows
26 PDP++	ftp://cnbc.cmu.edu/pub/pdp++/	Simulador de RNA	Unix, Windows
27 Basis of AI-NN Software	http://www.doniveter.com/ai/soft/nnsoft.html	Simulador de RNA	Unix, Windows 3.x

Quadro 3.3 – Simuladores de RNA's

## CAPÍTULO IV

# MODELO CONCEITUAL DE SIMULAÇÃO CHUVA-VAZÃO UTILIZANDO RNA'S

### 4.1 Descrição das Situações Objeto de Pesquisa

Consoante aos objetivos definidos, a pesquisa se desenvolveu através da formulação de quatro situações básicas para a modelagem da relação chuva-vazão através de RNA (denominadas Caso 1, Caso 2, Caso 3 e Caso 4 no capítulo V), cada qual com um conjunto próprio de variáveis de entrada e sempre com a mesma variável de saída, a vazão fluvial para a bacia em estudo. A diferenciação nas variáveis de entrada visa permitir identificar os benefícios adicionais, em termos de capacidade preditiva, que cada conjunto de variáveis pode proporcionar. Assim, distinguem-se as quatro situações que se seguem, excludentes entre si, que formarão a base exploratória do trabalho de pesquisa:

- **Caso 1:** Corresponde à situação em que a variável de entrada é o total de precipitação mensal, calculado como o valor médio para a bacia como um todo através do Método de

Thiessen. Esta situação representa uma condição mínima de informação sobre o processo de transformação chuva-vazão e, foi formulada exatamente para verificar a capacidade dos modelos de RNA extrair informação do processo (aprendizado) sem qualquer conhecimento das leis físicas subjacentes a ele;

- **Caso 2:** Corresponde à situação em que o modelo de RNA toma como entrada os valores mensais, de escoamento básico e escoamento superficial (duas entradas), de um certo período de observação, obtidos através do “fracionamento” desses componentes gerados pela aplicação do modelo SMAP à série original de precipitações mensais daquele mesmo período. O modelo SMAP é aplicado após ter sido satisfatoriamente calibrado para aquele mesmo período. Trata-se de uma situação em que o modelo de RNA irá trabalhar com uma informação já depurada, a qual considerou os processos físicos de transformação previamente através do uso do SMAP. Esta situação, ainda que em certa medida “viciada” pela utilização do SMAP (com os erros da calibração e simplificações desse modelo), permitirá avaliar o ganho de qualidade dos resultados da previsão devido à inserção da representação de parte dos processos físicos de transformação chuva-vazão.
- **Caso 3:** Corresponde à situação em que a entrada é formada por variáveis de estado indicativas do armazenamento de água na bacia, traduzidos pelos volumes de água do reservatório subterrâneo e reservatório solo, também obtidos pelo SMAP para um certo trecho da série observada. Ou seja, com finalidade semelhante àquela descrita no Caso 2, trabalha-se com novas variáveis de entrada, também depuradas pela transformação parcial de componentes do processo chuva-vazão.
- **Caso 4:** Este caso corresponde ao pior nível de qualidade de informação pois a entrada é constituída dos vetores de precipitação mensal observados nos diversos postos pluviométricos da bacia, sem a composição do valor médio para a bacia (ou seja, sem aplicação do Método de Thiessen). A razão para ser proposto é novamente a intenção de verificar a capacidade da RNA em extrair informação diretamente dos dados, tenham eles significado físico ou não. É claro que quando se calcula o valor médio de precipitação mensal na bacia pelo método de Thiessen ou, através de outro método qualquer, existem aproximações decorrentes das hipóteses que são feitas (ex. formulação da “área de

influência do posto” segundo os polígonos de Thiessen; uniformidade da chuva ao longo de toda a área de influência). A pergunta que se faz é: terá a RNA capacidade de melhorar os resultados da previsão se utilizar diretamente os dados mensais de cada posto (entrada do vetor terá dimensão igual ao número de postos na bacia) ao invés de calcular um valor médio de precipitação para a bacia?

Além dos casos formulados para avaliar o desempenho da RNA conforme descrito anteriormente, será utilizado o próprio modelo SMAP, seja para ter um conjunto de valores de vazão de saída como referência para cada bacia estudada, bem como, para gerar as variáveis de entrada que serão utilizadas nos casos (2) e (3). Para que se tenha uma idéia clara das formulações que serão empregadas, apresenta-se a seguir uma descrição pormenorizada de cada uma delas, incluindo também uma revisão da estrutura do SMAP (intervalo mensal).

## 4.2 Modelo de Simulação Hidrológica - SMAPm

O modelo de simulação de séries contínuas do tipo transformação chuva-vazão denominado SMAPm foi desenvolvido por LOPES et al. (1981). Conforme suas características, este modelo enquadra-se naqueles cujo sistema é dito ser discreto, distribuído, determinístico e conceitual. De acordo com discretização adotada à da bacia hidrográfica pelos autores, o modelo possui estrutura simples de simulação hidrológica e apresenta intervalo de discretização mensal, com grande aplicação quando não se dispõe de dados em intervalos menores e, principalmente, quando o objetivo é gerar série de vazões que irão alimentar modelo de simulação de operação de reservatórios.

O *software* apresenta tela de operação desenvolvida em *Visual Basic 4.0* para ambiente *Windows*. Existe também a versão SMAP em nível diário. A versão mensal a ser trabalhada como objeto de estudo é a SMAPm - v.99 - Calibração Semi-Automática do Modelo SMAPm.

Este modelo tem sua aplicação reconhecida em vários estudos de aproveitamento hídricos. LOPES et al. (1981) apresentaram o modelo SMAP em uma versão simplificada, aplicada a intervalos de tempo diário e mensal em três bacias paulistas e uma bacia de rio intermitente do nordeste brasileiro. Demonstrando o aspecto prático do modelo diante dos problemas de falhas de dados e distribuição deficiente dos postos de chuva, LOPES e PORTO (1991) aplicaram dois algoritmos de otimização para calibrar os parâmetros do modelo, o método de Busca Direta e o método de Pesquisa Global, em uma versão mensal, a diferentes bacias hidrográficas do Brasil, inclusive a Amazônica e a do Tocantins. Visando desenvolver um procedimento sistemático de calibração do modelo, AZEVEDO et al. (1991) usaram um programa de computador - SMAPEX, que incorpora conhecimentos, os quais permitem atuar de maneira semelhante a um especialista humano (*Expert Systems*), em que gera um arquivo inicial de parâmetros e suas respectivas faixas de variação, a partir das recomendações de um especialista. THOMAZ et al. (1991), apresentaram uma alternativa de escolha do valor inicial de calibração de parâmetros, para superação das dificuldades observadas quando o ponto inicial estiver na região de superfície, em que são encontrados mínimos locais, pontos de sela, regiões de indiferenças e vales alongados.

A escolha deste modelo e seu *software* se deram por razões de simplicidade e eficiência do programa, além da estrutura da rede, do número reduzido de parâmetros a serem calibrados, que facilitam a confecção da arquitetura e a implementação e análise dos resultados do modelo de redes neurais artificiais equivalentes.

#### **4.1.1      *Descrição do Modelo SMAPm***

O modelo representa os processos do ciclo hidrológico e utiliza a separação dos escoamentos, baseada nos parâmetros do U.S. Soil Conservation Service (SCS) do Departamento de Agricultura dos Estados Unidos. A estrutura do modelo é constituída por dois reservatórios

lineares que simulam os fenômenos naturais, sendo que um está localizado na camada superior do solo e o segundo reservatório é subterrâneo (Figura 4.1).

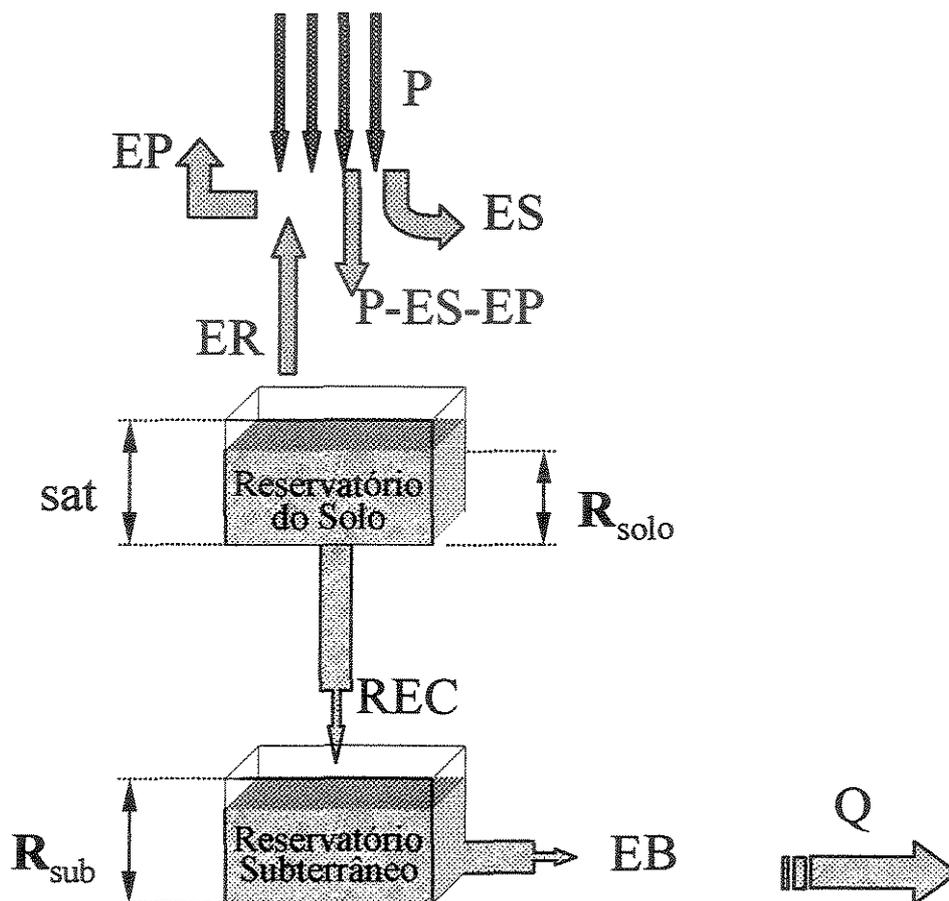


Figura 4.1 - Arquitetura do Modelo SMAPm na Versão Mensal

A base de dados de entrada do modelo está estruturado nas seguintes informações: dados físicos da bacia (área da bacia, características da sua drenagem, tipo de solo e subsolo, cobertura vegetal, e variáveis de entrada intermediária e de saída (variáveis temporais que retratam o comportamento da bacia, como a precipitação média, evaporação e vazão média).

A obtenção das séries mensais hidrológicas referentes às variáveis de entrada do modelo – precipitação, evaporação e vazão -, requer uma cuidadosa análise destes dados, quanto a sua qualidade, representação da variabilidade temporal e espacial, contribuindo para a redução de erros que comprometem a qualidade dos hidrogramas de saída.

Os métodos de estimativa usados para a determinação da precipitação média espacial são o método de Thiessen, método das Isoietas e métodos Geoestatísticos (*kriging*). As séries extraídas de uma densa rede de pluviômetros e pluviógrafos, e quando possível, de radar foram selecionadas na rede pluviométrica da Agência Nacional de Energia Elétrica (ANEEL), através do Banco de Dados Pluviométricos do Estado de São, Paulo, FCTH (1997a).

Neste trabalho, adota-se o método de Thiessen para a determinação do peso da área de influência de cada posto pluviométrico selecionado, para as respectivas bacias de estudo. O método é baseado na geometria do plano de posicionamento dos postos, com vista à ponderação da influencia relativa aos dados destinados ao cálculo da precipitação média da aérea em estudo, respeitando-se os limites topográficos e a orografia.

A metodologia de cálculo consiste nos seguintes procedimentos:

- *Passo 1:* Em um mapa topográfico, delimite a área da bacia através de seu divisor topográfico;
- *Passo 2:* Calcule a área total da bacia;
- *Passo 3:* Localize, em planta, os pontos dos postos selecionados;
- *Passo 4:* Ligue estes pontos em planta;
- *Passo 5:* Trace as mediatrizes das linhas de ligação dos pontos (linha perpendicular na metade da reta de ligação entre postos);
- *Passo 6:* A área de influência de cada postos é delimitada pelo prolongamento das bissetrizes;
- *Passo 7:* Calcule cada área de influência referente a cada posto;

A expressão que calcula a precipitação média é a seguinte:

$$\bar{P} = \frac{\sum_{i=1}^n P_i A_i}{A_t} \quad (4.1)$$

sendo  $A_i$  é a área de influência do posto  $i$  com relação a precipitação  $P_i$  e  $A_t$  é a área total da bacia. Alguns fatores, como características topográficas, tipo de precipitação e de desenvolvimento, podem promover estimativas inadequadas da precipitação, em função da dinâmica de cada evento.

- *Passo 8*: obtenção do peso da área de influência do posto:

O *peso* ou *fator de peso* é calculado pela expressão:  $w_i^1 = \frac{A_i}{A_t}$ , para o posto  $i$ , sendo  $A_i$  a área total da bacia.

Os dados são tabulados, segundo as seguintes informações:

<i>Posto</i>	<i>Área</i>	<i>Peso</i>	<i>Precipitação Média</i>
<i>Prefixo</i>	<i>km<sup>2</sup></i>	<i>w<sub>i</sub><sup>1</sup></i>	<i>P<sub>i</sub> (mm)</i>

A série mensal da variável evaporação é obtida por métodos diretos (evaporímetro de Piché; evaporação de tanque classe A e medidas de variáveis climáticas que permitam o cálculo da evapotranspiração potencial). Os métodos de estimativa indiretos da evapotranspiração potencial são o *Método de Thornthwaite* (correlaciona a temperatura do ar com a evapotranspiração estimada com base nos dados de precipitação e escoamento) e o *Método Modificado de Penman* (baseado no balanço da radiação da superfície) A evaporação potencial é representada por  $E_p$ . A série foi extraída de estação meteorológica, embora, a rigor, a evaporação não apresente grande variabilidade espacial e temporal, o posto escolhido está localizado fora da bacia hidrográfica, o que não compromete a boa estimativa do modelo.

As séries fluviométrica selecionadas de uma densa rede de fluviômetros e fluviógrafos, foram compiladas na rede fluviométrica da Agência Nacional de Energia Elétrica (ANEEL), através do Banco de Dados Fluviométricos do Estado de São, Paulo, FCTH (1997b) .

O balanço de umidade na camada superior do solo é realizado da seguinte forma (LOPES et al. 1981 e 1983):

1. Para cada chuva ( $P$ ) ocorrida, é realizado um balanço de massa. Uma parte da chuva é transferida como escoamento superficial ( $ES$ ) através da equação do Soil Conservation Service (SCS), e a outra lâmina de água restante ( $P-ES$ ) é reduzida por meio da evaporação a nível potencial ( $EP$ );
2. No primeiro estágio ocorrem os processos de interceptação, retenção superficial e retenção capilar. A lâmina remanescente ( $P-ES-EP$ ) vai para o reservatório solo e nele a umidade é atualizada ao longo do tempo através de perdas por evapotranspiração real ( $ER$ ), que eqüivale à evaporação potencial ( $EP$ ) vezes a taxa de umidade do reservatório (nível atual,  $R_{solo}$ ) dividido pelo nível máximo (capacidade de saturação,  $sat$ ), a outra saída deste reservatório corresponde a recarga no reservatório linear subterrâneo;

Com relação à estrutura do modelo escolhida pelos autores, esta utiliza a separação de escoamento com base nos parâmetros do SCS.

O SCS, com base na **Figura 4.2** considerou algumas proposições matemáticas, para a obtenção da expressão do escoamento superficial direto, apresentadas a seguir.

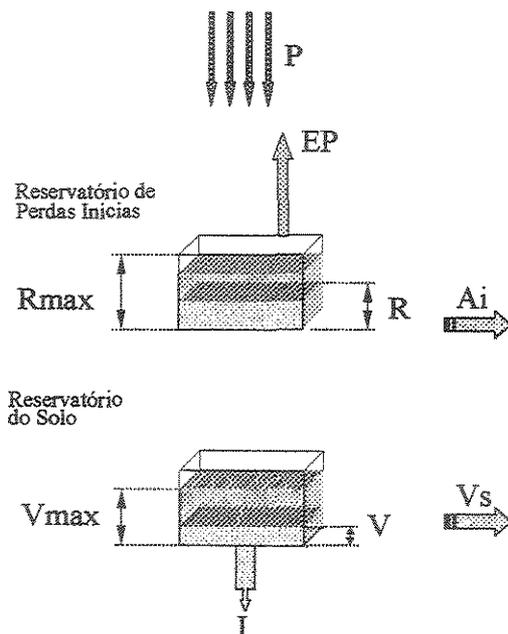


Figura 4.2 - Representação de Reservatórios para o Balanço de Umidade do Solo

A representação matemática do balanço de umidade na camada superior do solo considera a seguinte relação:

$$\frac{I}{S} = \frac{V_s}{P} \quad (4.2)$$

Em que,  $I$  representa a infiltração;  $S$  é o volume disponível para umidade no reservatório superior do solo (ou retenção potencial do solo,  $mm$ );  $V_s$  é o volume superficial que gera escoamento e,  $P$  é a precipitação (em  $mm$ ) que chega ao solo e não é retida por depressões e vegetações ( $P-A_i$ ).

Seja o reservatório com perdas iniciais com capacidade  $R_{max}$ , num intervalo de tempo  $t$ , com o volume retido sendo  $R$  e a abstração inicial<sup>1</sup> dada por:

$$A_i = R_{max} - R + E_p \quad (4.3)$$

<sup>1</sup> Nas situações em que  $A_i < 0$ , na expressão (4.2), ela passa a ser considerada  $A_i = 0$ .

No SMAPm o valor padrão de  $A_i$  é igual a 20% de  $S$ .

Considere agora o reservatório do solo, o qual possui a capacidade  $V_{max}$  e num certo tempo  $t$ , a umidade igual a  $V$ . Sendo assim, o volume disponível é calculado pela expressão

$$S = V_{max} - V \quad (4.4)$$

e, a infiltração calculada por

$$I = P - V_s \quad (4.5)$$

Substituindo as expressões (4.3), (4.4) e (4.5) em (4.2) e fazendo as devidas simplificações, obtém-se a equação do escoamento superficial, em  $mm$ , proposta pelo método SCS:

$$ES = V_s = \frac{(P - A_i)^2}{P - A_i + S} \quad (4.6)$$

O passo a passo para o cálculo do escoamento superficial será:

- a) Determinar as condições de saturação dos solo;
- b) Determinar o grupo hidrológico do solo;
- c) Através da tabela de numeração das curvas de escoamento superficial de chuvas intensas, conforme o complexo hidrológico do solo com a sua cobertura vegetal (condição II de umidade antecedente); da cobertura vegetal e do grupo hidrológico, determinar o  $CN$  (é chamado de *número de curva* e varia entre 100 e 0) para a condição II;
- d) Transformar o  $CN$  para a condição desejada na tabela de conversão das curvas  $CN$  ( $CN$  é função do tipo de solo, ocupação do solo e umidade antecedente) para diferentes condições de umidade do solo;

- e) Uma vez com a curva  $CN$  conhecida e com a precipitação total, através das curvas de um gráfico Escoamento Superficial ( $ES$ ) X Precipitação ( $P$ ), entrar com o valor de  $P$  na curva  $CN$  correspondente e obter o valor do escoamento superficial.

O balanço de massa mensal correspondente é dado por:

$$R_{solo}(i+1) = R_{solo}(i) + P - ES - ER - REC \quad (4.7)$$

Em que:

$R_{solo}(i)$  é água armazenada no reservatório do solo (zona aerada) no início do mês, (mm);

$P$  é a precipitação total no mês (mm);

$ES$  é o escoamento superficial, (mm);

$ER$  é a evapotranspiração real (mm); e

$REC$  é a recarga subterrânea, (mm).

Os principais processos  $ER$ ,  $ES$  e  $REC$  são submetidos ao controle da taxa de umidade do solo:

$$TU = R_{solo}/sat \quad (4.8)$$

Sendo:

$sat$  é o parâmetro de calibração da capacidade de saturação do solo, (mm).

Os processos são representados por três variáveis e três funções de transferência:

$$ES = f_i * P \quad (4.9)$$

$$ER = f_2 * EP \quad (4.10)$$

$$REC = f_3 * R_{solo} \quad (4.11)$$

$$f_1 = TU^{pes} \quad (4.12)$$

$$f_2 = TU \quad (4.13)$$

$$f_3 = crec * TU^4 \quad (4.14)$$

Em que,

$EP$  é a evapotranspiração potencial do mês, (mm);

$f_1$ ,  $f_2$  e  $f_3$  são funções de transferência, onde  $f_2$  determina a fração de chuva que se transforma em escoamento superficial e  $f_3$  controla a altura de recarga.

$pes$  é o parâmetro de calibração do escoamento superficial (ad); e

$crec$  é o parâmetro de calibração que controla a percolação para o reservatório subterrâneo ou coeficiente de recarga, (adimensional).

3. Para o reservatório subterrâneo linear, a outra parcela de saída do reservatório solo é a recarga no reservatório subterrâneo ( $REC$ ), e a lâmina de água existente ( $R_{sub}$ ) é deplecionada a taxa constante  $k$  promovendo o escoamento básico ( $EB$ ).

A equação do balanço hídrico para o reservatório subterrâneo é dada por:

$$R_{sub}(i+1) = R_{sub}(i) + REC - EB \quad (4.15)$$

Sendo:

$R_{sub}(i)$  é água armazenada no reservatório subterrâneo (zona saturada) no início do mês, (mm); e

$EB$  é o escoamento básico, (mm).

4. A soma dos escoamentos superficial ( $ES$ ) e básico ( $EB$ ) dão origem a vazão no ponto de controle ou saída da bacia.

A vazão básica é dada pela expressão:

$$EB = f_A \cdot R_{sub} \quad (4.16)$$

$$f_A = 1 - k \quad (4.17)$$

Em que:

$f_A$  é a função de transferência do aquífero para o rio; e

$k$  é a constante de recessão do escoamento básico ( $\text{mês}^{-1}$ )

Para o cálculo da vazão a equação é representada por:

$$Q = (ES + EB) \cdot Ad / 2630 \quad (4.18)$$

Sendo:

$Q$  é a vazão calculada pelo modelo, mm, e

$Ad$  é a área da bacia contribuinte,  $\text{km}^2$ .

Seguindo o passo-a-passo da estrutura de cálculo, os dados básicos do modelo são a série mensal de chuva e as médias multimensais de evaporação potencial (tanque classe A), e os reservatórios são atualizados de maneira contínua para cada intervalo de tempo discretizado no modelo. No procedimento da atualização, é aplicada uma abstração potencial variável a ser empregada na equação do volume escoamento superficial do SCS. A explicação da técnica do SCS pode ser vista em LOPES et al. (1983) e TUCCI (1987).

Com relação á obtenção dos dados referentes aos coeficientes de ajuste da chuva média da bacia – *pcof*, e ajuste da evaporação média da bacia – *ecof*, estes serão calculados em função da distribuição espacial dos postos. Para o coeficiente *ecof*, este deverá ser igual a 1 por se tratar apenas de um posto evaporimétrico para cada bacia em estudo. Quanto aos outros coeficientes, *pcof*, alguns procedimentos serão executados para a sua determinação com base no número de postos pluviométricos existentes em cada bacia, a saber:

- a) é necessário selecionar os mapas topográficos, para que seja demarcada ou digitalizada a área das bacias. É importante levar em conta o efeito de escala na obtenção de dados. COELHO (1998) recomenda que para pequenas bacias a escala indicada não deve ser grande, pois a análise fica comprometida devido à perda de muitos detalhes da rede de drenagem, bem como não deve ser muito baixa; a escala de 1:50000 é a indicada;
- b) os postos escolhidos serão plotados no mapa da bacia e a seguir é aplicado o método de Thiessen para o cálculo das sub-áreas de influência de cada posto, respectivamente,
- c) obtenção do peso da área de influência do posto (*pcof*).

Para a calibração, considerando a capacidade desta versão, serão necessários um período de 2 a 9 anos de dados de vazão média mensal, e até 9 postos de chuva por bacia. A descrição do procedimento de cálculo da calibração do modelo é vista a seguir.

#### **4.1.2 Metodologia de Calibração**

Calibrar um modelo é determinar um conjunto de parâmetros que melhor represente o processo de transformação de chuva em vazão. Um dos critérios atribuídos é o de minimizar os desvios entre os hidrogramas observados e aqueles calculados pelo modelo.

A faixa de variação dos parâmetros de calibração deve ser definida pelo usuário, e os limites para cada um dos parâmetros aplicados a modelos em bacias de regiões brasileiras (LOPES e PORTO, 1991) são:

$$500 < \text{sat} < 4000$$

$$1 < \text{pes} < 10$$

$$0,01 < \text{crec} < 0,64$$

O quarto parâmetro de calibração - constante de recessão  $k$  (ver **Tabela 4.1**), não foi utilizado na calibração automática do modelo, pois não apresentou sensibilidade às funções objetivos aplicadas. LOPES e PORTO (1991) indicam que seja feito o ajuste de forma manual após os três outros parâmetros terem sido ajustados.

**Tabela 4.1 - Parâmetro de Calibração da Constante de Recessão,  $k$**

<i>Número de Meses ((hh)</i>	<i>Classificação</i>	<i>k</i>
1 mês	Muito Rápido	0,5000
2 meses	Rápido	0,7071
3 meses	Médio	0,7937
4 meses	Lento	0,8409
6 meses	Muito Lento	0,8909

Fonte: Programa SMAPv.99, versão mensal

Para a calibração do modelo SMAPm são necessários de 2 a 9 anos de dados de vazão média mensal observada.

Dentre os métodos matemáticos aplicados na calibração de modelos, foi utilizado no SMAPm o *algoritmo de Rosenbrock* na determinação do valor ótimo dos parâmetros. Este algoritmo de otimização dos parâmetros pertence ao grupo daqueles métodos que utilizam a busca multidimensional, os quais não usam derivadas; além disso, apresenta alguns problemas em localizar pontos ótimos locais.

BAZARAA (1993) descreve a construção das direções de busca do método, para a minimização de uma função de várias variáveis, usando a técnicas de *busca linear* e a dos *passos discretos*.

Estas técnicas têm por finalidade reduzir o tempo de processamento de cálculo do ajuste do modelo, porém não torna excludente uma verificação mais refinada.

TUCCI (1998) ressalta que os métodos matemáticos, cuja técnica iterativa de otimização dos parâmetros são aplicadas, ainda apresentam algumas limitações, tais como:

1. *" a função objetivo nem sempre retrata bem o comportamento esperado das curvas, apresentando anomalias na vizinhança da solução;*
2. *a solução pode convergir para parâmetros inconsistentes, já que existem infinitas soluções matemáticas possíveis, mas irrealis do ponto de vista físico;*
3. *o mínimo obtido pode ser local e não global, pois depende muito do ponto de partida;*
4. *quando o número de parâmetros cresce muito, por exemplo quando se divide a bacia em um grande número de sub-bacias, e a série simulada envolve muitos intervalos de tempo, o processo pode ser lento e o usuário perde a noção do desejado ótimo;*
5. *quando existem muitas incertezas nos dados observados, as mesmas são transferidas para o ajuste, o que pode provocar resultados absurdos;*
6. *interdependência entre os parâmetros;*
7. *descontinuidades da função objetivo devido as características da estrutura do modelo".*

De maneira geral, nos modelos do tipo conceitual que utilizam técnicas iterativas na otimização dos parâmetros, é recomendável um estudo de sensibilidade dos parâmetros estabelecidos. No caso particular do modelo SMAPm, a análise de sensibilidade dos três

parâmetros é precedida do método iterativo. A finalidade deste estudo é dar uma melhor definição quanto a escolha dos parâmetros mais sensíveis que serão otimizados; estimar os parâmetros que apresentem pouca sensibilidade e, neste caso, fixar um valor; estabelecer os limites de variação dos parâmetros sujeitos ou não às restrições; definir um critério para a interrupção da otimização de acordo com a técnica iterativa utilizada, isto é, número máximo de tentativas, variação da função objetivo e número máximo de ciclo e finalmente, estipular o espaçamento da variação dos parâmetros.

O algoritmo de otimização aplicado no modelo SMAPm é voltado às funções unimodais e não garantem a obtenção do mínimo global da função, em virtude das funções resultantes do modelo serem bastantes complexa. Neste caso, para solucionar o problema de mínimos globais, após utilizar o método iterativo, aplica-se um segundo processo complementando o primeiro na melhora dos resultados.

O processo implementado foi à técnica de *Pesquisa Global* de otimização dos parâmetros, a qual oferece um auxílio ao processo de calibração. Esta é uma das estratégias de busca global a qual é designada para descobrir de forma eficiente o mínimo global de funções multimodais. Consiste em rodar o modelo para os valores existentes entre os limites estabelecidos para os parâmetros de calibração, isto é, não há necessidade de se atribuir valores iniciais. Assim, uma varredura da superfície definida pela função objetivo é realizada, e, desta forma, promove a aproximação do ponto ótimo de calibração de modelos do tipo chuva-vazão. Um valor mínimo da função objetivo é escolhido e são selecionados os parâmetros correspondentes, para posteriormente rodar novamente o modelo. Este procedimento é repetido até que não haja mais variação significativa do valor da função objetivo.

No modelo SMAPm, foram considerados 3 parâmetros, portanto tem-se 4 dimensões. A visualização das superfícies da função objetivo, durante a análise de sensibilidade dos parâmetros, é dada por três matrizes as quais representam cortes das superfícies em que se fixa um dos parâmetros e variam os outros dois para cada matriz (ex: fixa *sat* e varia *pes* e *crec* ). O valor mínimo da função objetivo é então registrado. Estas matrizes traduzem um *layout* da sensibilidade

dos parâmetros. A técnica de Pesquisa Global, levando-se em conta a escolha do melhor valor para os parâmetros, proporciona maior confiabilidade aos resultados.

É um método muito mais seguro, como também é reduzido o tempo de processamento computacional na busca do mínimo global (LOPES e PORTO, 1991). A expressão que estabelece a discretização dos parâmetros é dada por:

$$Pr(i) = Pr^* \cdot 2^{\left(\frac{i-4}{2+lp}\right)} \quad (4.19)$$

Sendo:

$Pr(i)$  é o vetor de parâmetros a serem testados;

$Pr^*$  é o parâmetro ótimo do *loop* anterior;

$i$  é o índice de discretização do parâmetro (de 1 a 7), e

$lp$  é o número de loop (nível de *zoom*) (de 1 a n).

É recomendável escolher a série hidrológica com início correspondente ao primeiro mês do ano hidrológico da bacia a ser simulada, e que a inicialização da calibração procederá pelo mês mais seco em virtude de neste período a umidade do solo e vazão básica apresentarem seus valores mínimos. Outra recomendação é quanto ao ajuste manual na inicialização das variáveis de estado  $R_{solo}$  e  $R_{sub}$ . No caso do reservatório solo

*“... verificar se o valor atribuído está dentro da faixa de variação apresentada na simulação de todo o período, caso contrário ressimule alterando seu valor observando também a aderência do hidrograma no instante inicial”, e para o reservatório subterrâneo “... pode ser atribuída a vazão básica inicial igual a vazão mínima do período e verificar no hidrograma se existe tendências crescentes ou decrescentes na vazão básica ao longo do período”.*(LOPES e PORTO, 1991)

A função objetivo adequada a um modelo hidrológico deve abstrair, eficientemente, as informações contidas nos dados fornecidos, bem como deve atender ao uso do modelo. As funções às quais são baseadas na teoria da máxima verossimilhança têm maior capacidade de

retirar estas informações do que àquelas baseadas na teoria dos mínimos quadrados (SOOROSHIAN et al., 1983).

A escolha da função objetivo do tipo somatória dos desvios quadráticos, dentre aquelas funções mais usuais, justifica-se pelo fato de que o objetivo deste estudo é o cálculo das vazões médias mensais. Mas isto não impede que, em outra finalidade específica, seja adotada uma *função objetivo* mais conveniente à aplicação. Por exemplo, em caso de estudos de regularização de reservatórios, a função objetivo (denominada módulo) seria a diferença entre o volume total afluente, a partir da série observada e da série simulada, pois neste caso, a preocupação está voltada para o período crítico.

O modelo SMAPm após ser testado com vários tipos de função objetivo e aplicadas a diversas regiões com diferentes regimes hidrológicos, os autores optaram por escolher a expressão matemática da *função objetivo* do tipo quadrática, como segue:

- Para rios perenes toma-se a soma dos desvios relativos quadráticos ou função relativa, traduzida por:

$$\text{Min} \sum_1^n \left( \frac{QO_i - QC_i}{QO_i} \right)^2 \quad (4.20)$$

Sendo:

$QO_i$ , as vazões observadas e

$QC_i$  as vazões calculadas ou simuladas pelo modelo.

- Para rios intermitentes toma-se a soma dos desvios absolutos quadráticos ou função quadrática, traduzida por:

$$\text{Min} \sum_1^n (QO_i - QC_i)^2 \quad (4.21)$$

Considerando que o modelo seja destinado a previsões de cheias, em que a ênfase é dada para vazões maiores, a função objetivo poderá ser do tipo quadrática. No caso de modelos de simulação de séries temporais de vazões, cuja finalidade seja a obtenção ou o dimensionamento de reservatórios, o ajuste requer uma boa aproximação entre as vazões calculadas e observadas, neste caso, recomenda-se a função do tipo relativa.

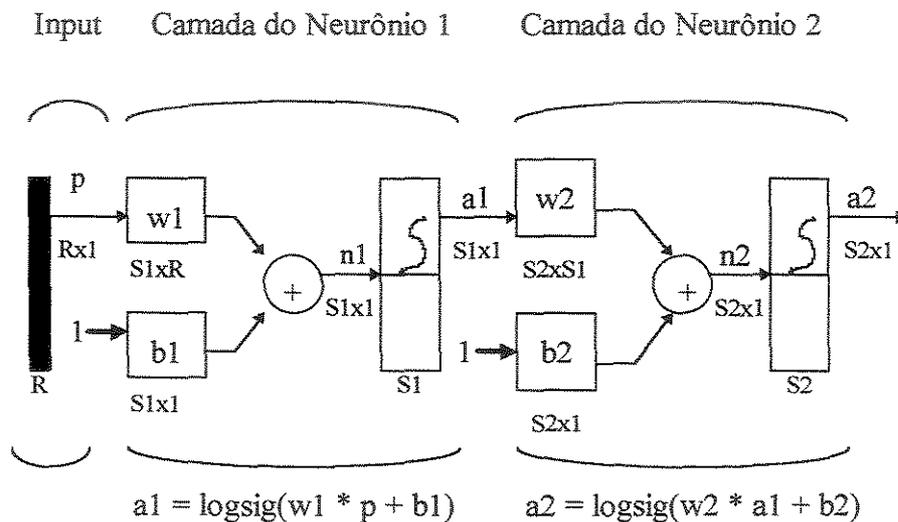
A escolha de uma função objetivo, que possa melhor ajustar a série gerada às finalidades pretendidas do modelo, não se constitui apenas como um único indicador de uma calibração ideal, mesmo que o hidrograma seja cuidadosamente analisado pelo hidrólogo. É relevante considerar, além da função objetivo, dois outros indicadores a serem verificados durante o processo de calibração, tais como:

- a) o armazenamento do período (balanço) deve ser próximo de zero, para que seja verificada a ocorrência de retenção ou liberação de água proveniente do reservatório do solo de forma tendenciosa – a variação dos reservatórios deve ser cíclica e acompanhar a sazonalidade de cada região e,
- b) a recarga e o escoamento básico devem ser aproximadamente iguais, para que sejam verificados problemas com relação aos parâmetros  $crec$  e  $k$ , caso ocorra uma diferença nestes valores.

### 4.3 Algoritmo Proposto para Simulação Chuva-Vazão através de RNA's

#### 4.3.1 Topologia da Rede Proposta

A notação da estrutura de rede a ser adotada no estudo de caso seguirá aquela indicada pela linguagem de programação empregada MATLAB<sup>®</sup> 5.2, como ilustra a **Figura 4.3**.



**Figura 4.3 - Notação Abreviada de uma Rede de Neurônios com Multicamadas**

Em que:

**R** são os dados de entrada (*inputs*), **S1** é a camada 1 de neurônio e **S2** é a camada 2 de neurônios, **Rx1**, é a dimensão do vetor coluna **p** da entrada **R** da rede e a função de transferência **F** é do tipo *log-sigmoid*.

A topologia da RMC a ser treinada foi definida tendo como referência o sistema hidrológico apresentado pelo modelo SMAP, versão mensal. A partir daí, estruturou-se uma

topologia (**Figura 4.4**), com base nos seguintes critérios, visando ao melhor desempenho do algoritmo BP:

- *número de neurônio a ser utilizado por camada*

Na prática não existe uma regra definida para se estabelecer o número inicial de neurônios. Existem algumas indicações que auxiliam como primeira tentativa, dentre elas, aplicaremos a que indica para camada de entrada (variáveis independentes) um número de neurônios igual ao número de variáveis de entrada (p.ex, Caso 1, um neurônio na camada de entrada que representa os dados de precipitação). O número de neurônios da camada escondida deve ser o menor possível, mas, como primeira tentativa, treina-se a rede para um número bem alto de neurônios e verifica-se o comportamento do erro, se ele for muito alto, então se vai diminuindo até que o erro não se altere significativamente (p.ex, Caso 1, foram feitos treinamentos, dependendo da bacia simulada, para topologias variando entre 30 a 2 neurônios na camada escondida). Para a camada de saída, em todos os casos, foi considerado igual a um neurônio (vazões calculadas).

- *número de camadas*

Também para este caso, não existem regras estabelecidas e este valor fica em aberto. A rede foi treinada para 3 camadas fixas em todos os casos.

Notação de Rede Feed-forward com 3 Camadas

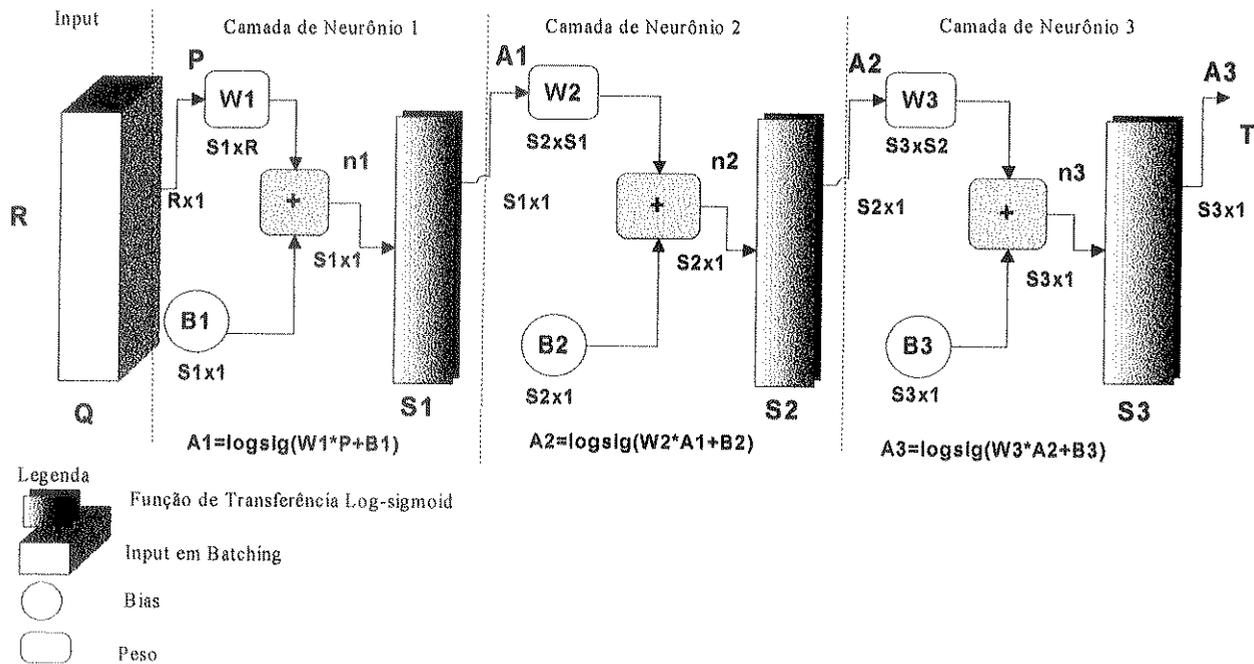


Figura 4.4- Notação de Rede Neural Artificial

Para o treinamento da rede, algumas topologias foram testadas, objetivando a verificação da performance da rede. Assim, por exemplo, uma das tentativas de treinamento segue a seguinte topologia: propôs-se, inicialmente, a construção de uma unidade para a camada de entrada, três unidades para a camada escondida e, finalmente, uma unidade para a camada de saída [Notação: RNA(1,3,1)]. A partir desta estrutura, foi aplicado o algoritmo de treinamento da rede.

Conforme já comentado na introdução desse capítulo (seção 4.1), o estudo das RNA para simulação dos processos chuva-vazão foi desenvolvido com base em quatro situações (denominadas casos), excludentes entre si.

A idéia de testar 4 concepções diferentes (casos) sobre a posição de inserção do modelo de RNA acoplado ao SMAPm, tem origem na necessidade de investigar o potencial das RNA's, para substituir os parâmetros e processos tradicionais dos modelos chuva-vazão, traduzindo-os na forma de topologia da rede, pesos sinápticos, etc. Nesta perspectiva, numa primeira versão, será avaliado o potencial das RNA's para representar diretamente a relação chuva-vazão, partindo-se portanto, como entrada, da série de precipitação (Caso 1) e gerando-se as vazões através da RNA, **Figura 4.5**. Numa segunda versão de topologia, toma-se como entrada para a RNA os valores dos escoramentos básico e superficial (Caso 2, **Figura 5.6**), gerados pelo SMAP. Na terceira versão de topologia (Caso 3) adota-se os volumes armazenados nos reservatórios solo e subterrâneos (**Figura 4.7**) como entrada para a RNA, também valores gerados pelo SMAPm. A topologia que representa o Caso 4 (**Figura 4.8**), corresponde a situações em que admite duas entradas de dados na rede, correspondendo aos registros de chuva de dois postos pluviométricos, pertencentes a área de influência da bacia. Em todas as versões a saída é formada pela vazão com discretização mensal para o período em estudo.

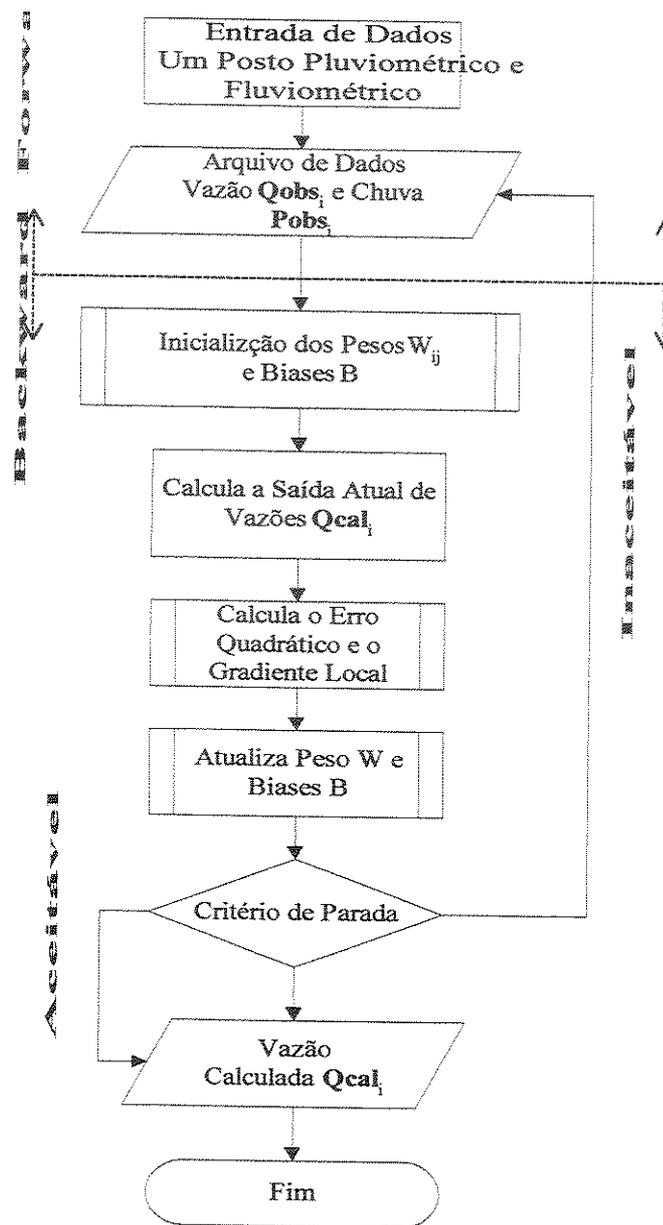


Figura 4.5- Caso 1: Relação Direta Precipitação-Vazão por RNA (um Posto Pluviométrico)

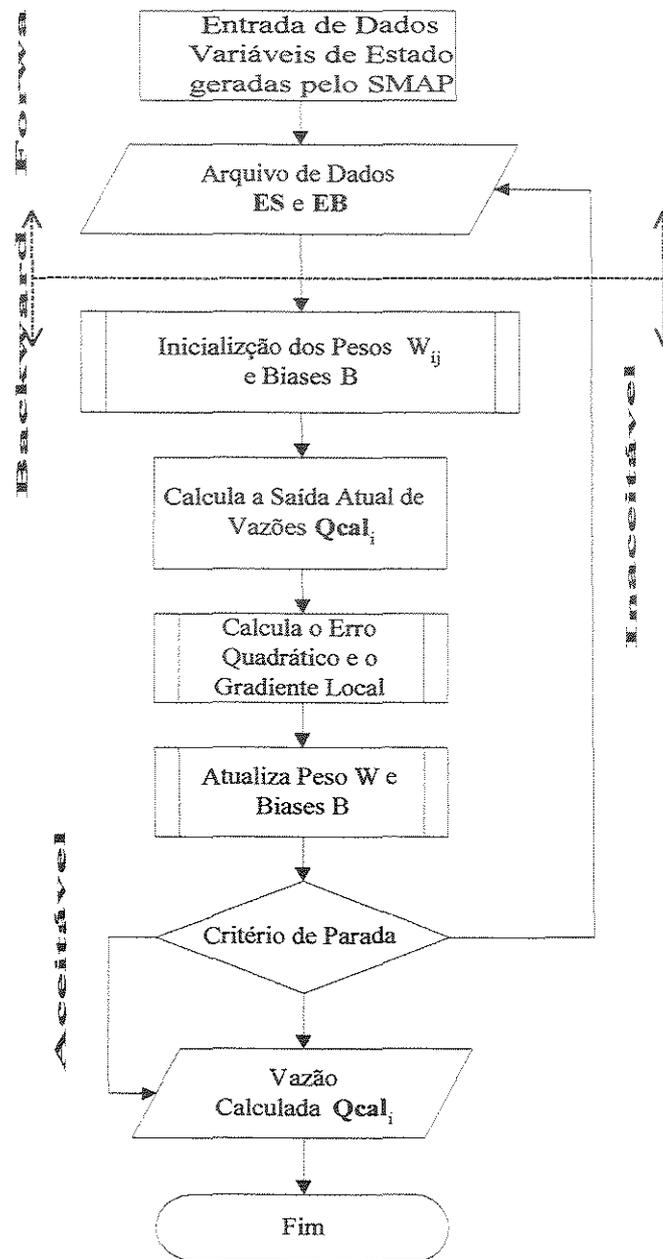


Figura 4.6 - Caso 2: Relação Precipitação-Escoamento por SMAP e escoamento-Vazão por RNA

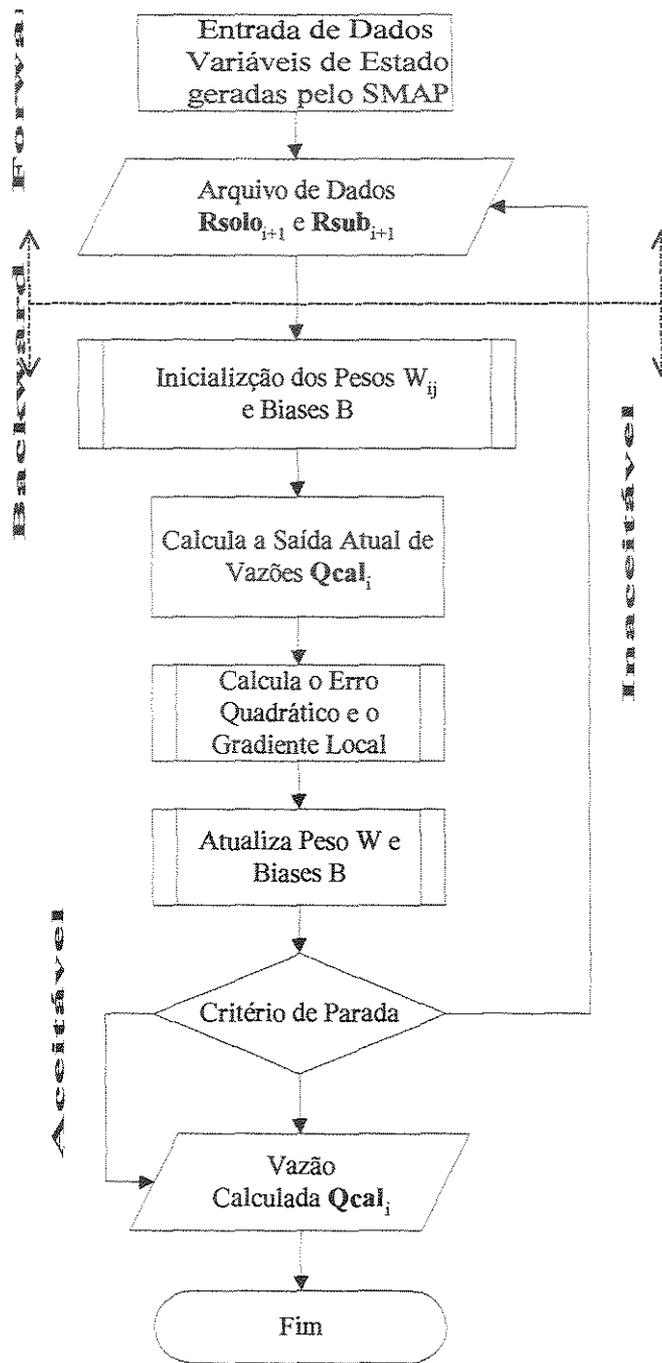


Figura 4.7 - Caso 3: Relação Precipitação-Volume por SMAP e Volume-Vazão por RNA

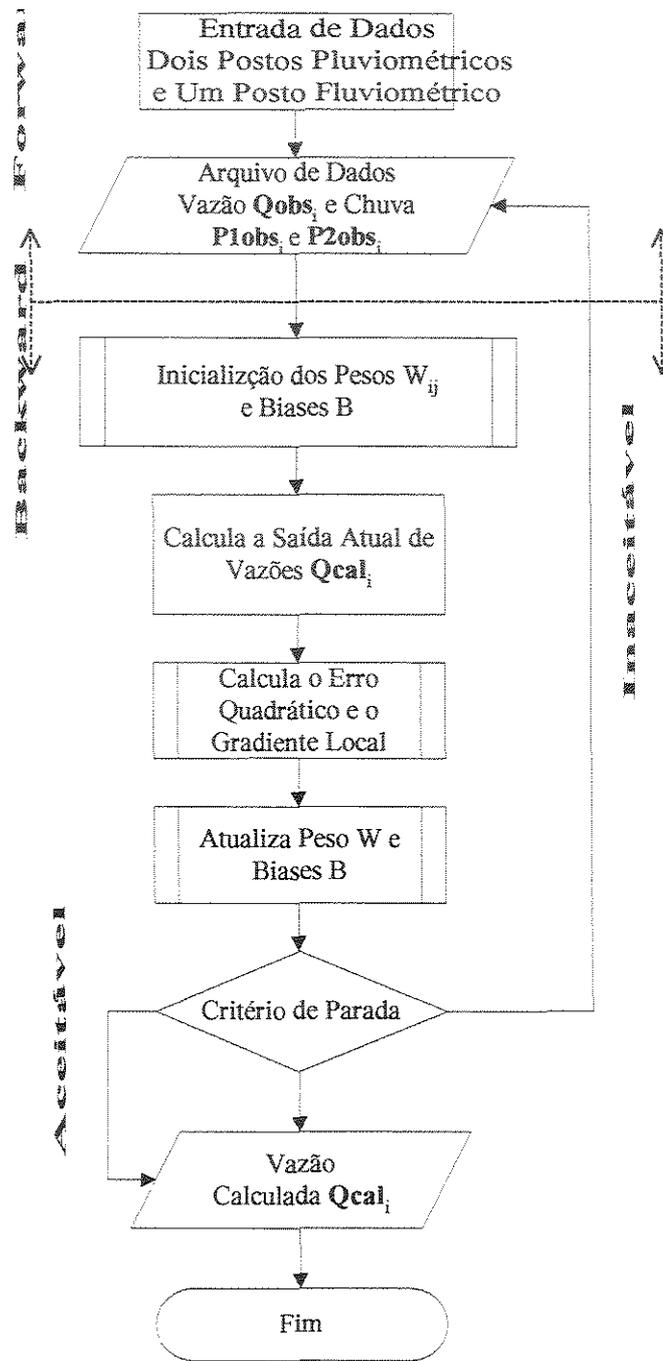


Figura 4.8 – Caso4: Relação Direta Precipitação-Vazão por RNA (dois Postos Pluviométricos)

### 4.3.2 *Algoritmo do Modelo Proposto*

O modelo de RNA's será simulado através do software MATLAB<sup>®</sup> 5.2 (Matrix Laboratory) for Windows, que é um ambiente computacional técnico para visualização e computação numérica de alta performance. O MATLAB<sup>®</sup> 5.2 integra análise numérica, processamento de sinais e gráficos, em que o problema e as soluções são expressos tal como são formulados matematicamente, sem a programação tradicional (MATHWORKS, 1998).

Em SANTOS e ROMERO (1994), descrevem-se os principais procedimentos de programação existentes para a implementação de RNA's e MOLLER (1993) e CASTRO e VON ZUBEN (1998) definem o algoritmo de treinamento otimizado para os casos do modelo neural proposto – algoritmo *do gradiente conjugado escalonado* (GCE) – comentado no capítulo 3.

Com exceção dos Casos 1 e 4, os demais terão uma *rotina de inicialização*<sup>2</sup> do modelo, em que estará sendo calculado o balanço hídrico do sistema e como produto final resultando nos escoamentos superficial e básico (Caso 2) e os volumes dos reservatórios superficial e subterrâneo (Caso 3).

A implementação desses procedimentos será apresentada no próximo capítulo, juntamente com os resultados obtidos nas simulações.

---

<sup>2</sup> Simula a inicialização do modelo atribuindo valores adequados para as variáveis (PERIN FILHO, 1995).

# CAPÍTULO V

## ESTUDO DE CASO

### 5.1 Introdução

Neste estudo de caso foram selecionadas quatro bacias hidrográficas com diferentes características físicas, cuja consistência das séries históricas e existência de dados (variáveis) atendessem as prerrogativas dos programas computacionais. As bacias escolhidas foram as dos rios Itapetininga, Almas e Guarapiranga no estado de São Paulo e a do rio Guaporé no estado de Mato Grosso. Uma descrição das características fisiográficas das regiões que compreendem as bacias simuladas, será feita de forma resumida.

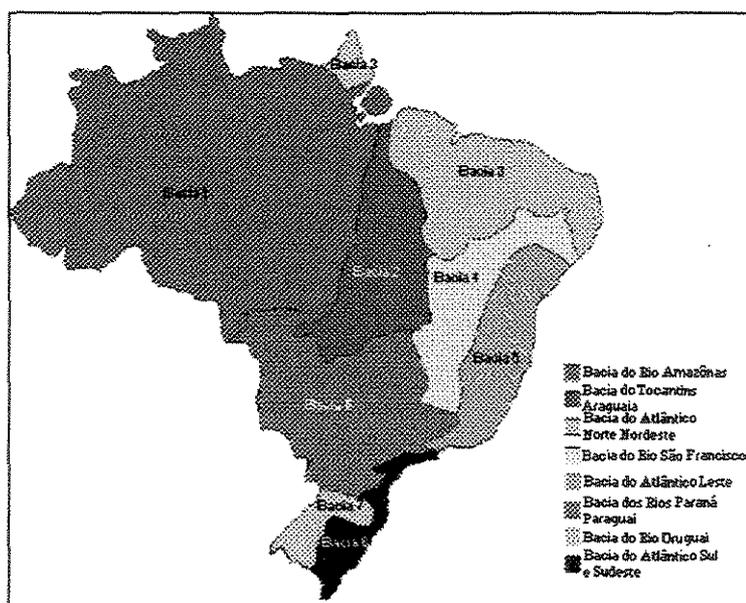
Os processos de execução dos programas computacionais serão vistos, na seqüência, de forma a apresentar os passos dos cálculos correspondentes as diversas alternativas escolhidas para as simulações. A análise dos resultados será feita com base em dois procedimentos: o primeiro será entender a dinâmica dos modelos e os respectivos comportamentos dos hidrogramas calculados em relação aos observados, conforme cada caso simulado; o segundo passo, tratando-se de um elemento de avaliação de desempenho dos modelos aplicados, serão realizadas as

análises estatísticas dos resultados com base nos resultados da validação dos modelos e quanto à parcimônia.

## 5.2 Alguns Aspectos Fisiográficos da Área de Estudo

As bacias selecionadas para o estudo de caso pertencem às regiões com características fisiográficas e sócio-econômicas bem distintas. A descrição sucinta de algumas características fisiográficas destas áreas terá como referências a subdivisão das bacias hidrográficas no Brasil, segundo o Inventário Fluviográfico de Bacias Hidrográficas (ANEEL, 1997).

A divisão das bacias hidrográficas no território nacional, segundo a Agência Nacional de Energia Elétrica (ANEEL), é constituída de 9 unidades (Figura 5.1).

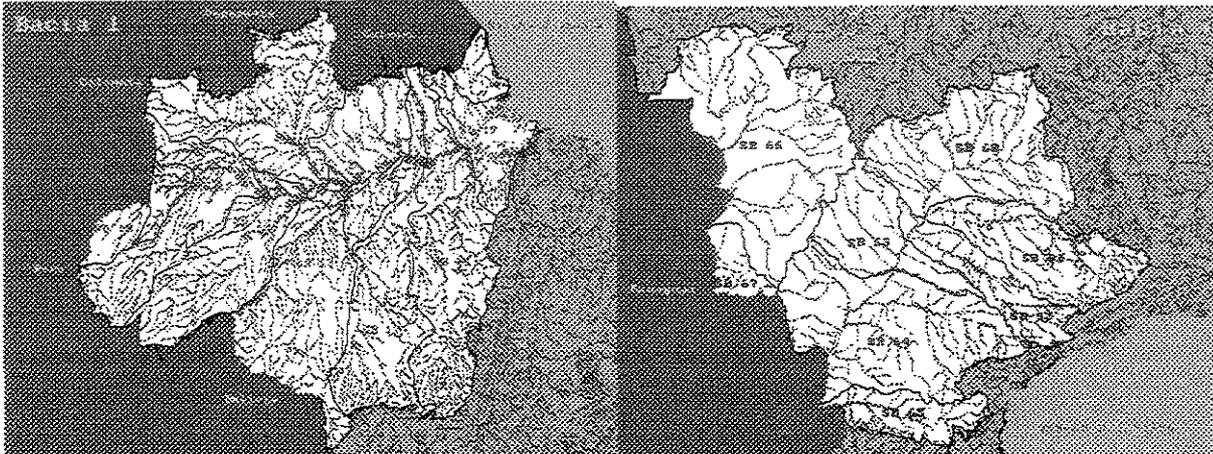


*Figura 5.1 - Brasil - Desenho Esquemático da Divisão das Bacias Hidrográficas*

Fonte: <http://www.aneel.com.br/>, (1999)

As bacias selecionadas, no estudo de caso fazem parte de uma das 10 sub-bacias do rio Amazonas (Bacia1) e de 3 das 8 sub-bacias dos rios Paraná e Paraguai (Bacia 6). A bacia do rio

Guaporé, pertencente à Bacia 1 e faz parte da bacia do rio Madeira (sub-bacia 15). As bacias dos rios Itapetininga e das Almas fazem parte da bacia da Bacia 6 e, pertencem à sub-bacia dos rios Paraná/ Paranapanema e Ivinhema (sub-bacia 64). Ainda na Bacia 6, está a bacia do rio Guarapiranga, que segunda a sub-divisão corresponde à sub-bacia de número 62, ou seja, à bacia do rio Tietê (Figura 5.2).



*Figura 5.2 - Brasil - Divisão das Bacias Hidrográficas 1 e 6*

Fonte: <http://www.ancel.com.br/>, (1999)

A bacia do rio Amazonas, cujo curso principal é o rio Amazonas (extensão de 6570 km) envolve uma área de drenagem da ordem de  $6 \times 10^6$  km<sup>2</sup>, onde deste valor, 42% corresponde a solo brasileiro e o restante dividido entre terras venezuelanas até as bolivianas, correspondendo a  $\frac{1}{4}$  da superfície da América do Sul. Caracteriza-se por possuir um elevado índice pluviométrico e construir o maior sistema fluvial mundial, por onde escoam cerca de  $\frac{1}{5}$  volume de água doce existente no planeta. Devido à sua localização, com relação a linha do Equador, a bacia possui influência de dois regimes fluviais, correspondentes aos dois hemisférios: no verão austral ou sul, a parte meridional (a maior) é a que recebe grande contribuição pluviométrica, ao passo que, no verão boreal ou norte, as precipitações são mais intensas na parte meridional.

O clima desta bacia é quente e úmido com período de 4 a 5 meses de clima seco, cuja variação da temperatura apresenta certa homogeneidade espacial e estacional, com média superior a 22°C. Apresenta solos profundos e pobres com lençóis freáticos, em média, a uma profundidade

---

entre 10 a 15 m. Das variações florestais da região, cerca de 90% são constituídas de florestas perenifólia hidrófila hileia na Amazônia, que corresponde à mata de terra firme; floresta perenifólia paludosa ribeirinha permanentemente inundada - mata de várzea; floresta perenifólia paludosa ribeirinha permanentemente inundada - mata de igapó e, floresta subcaducifólia Amazônica. Os tipos de cobertura vegetal não florestais encontrados são o cerrado, os campos, complexos de Roraima, Cachimbo e Xingu e, finalmente, a vegetação litorânea (vegetação dos mangues, que são constituídas de espécies arbustivas e arbóreas).

A Bacia 6 tem como rio principal o rio Paraná e seus afluentes e constitui o maior dos sistemas fluviários a desaguar no estuário do rio da Prata. A região possui uma grande diversidade de sua cobertura vegetal. Na sub-bacia 62 predomina a floresta tropical e, na sub-bacia 64, destaca-se a floresta tropical, mata de araucária e a pequenas formações de campos cerrados e cerrados. O relevo apresenta-se bem variado, com faixas acidentadas a leste, devido à Serra da Mantiqueira e na do Mar e a oeste encontram-se os planaltos seguidos das planícies, onde está o pantanal mato-grossense. Esta bacia está inserida, na sua maior parte, na zona de clima tropical, com máximo registro de totais médios anuais de pluviosidade em torno de 2200mm e evapotranspiração potencial, em média, entre 800 e 100mm na maior parte da bacia.

### **5.3 Metodologia de Avaliação dos Resultados dos Modelos**

Os programas computacionais, aplicados no estudo de caso, necessitaram de alguns procedimentos iniciais de caráter metodológico. Essas ações tiveram como objetivo não só melhorar a performance da simulação, como, também, de organizar as tarefas executadas, uma vez que pelo número de bacias simuladas e a quantidade de informações manipuladas, houve a necessidade de se aplicar tais medidas.

Como parte da interpretação dos resultados das simulações e seleção das melhores topologias de RNA, a metodologia estatística utilizada no estudo de caso está configurada em duas análises: uma com base nos resultados de validação e outra na parcimônia dos modelos hidrológicos.

### 5.3.1 *Modelo SMAPm*

Os procedimentos metodológicos aqui reportados denotam uma forma sistematizada de execução da simulação dos modelos propostos. Inicialmente foram realizados um inventário das estações hidrometeorológicas e disponibilidade de dados das variáveis requeridas, em várias bacias hidrográficas a fim de selecionar aquelas que provavelmente serão incluídas no estudo de caso.

A base de dados utilizada nesta busca teve como procedência o Banco de Dados da Agência Nacional de Energia Elétrica – ANEEL (<http://www.aneel.gov.br>), os Bancos de Dados Pluviométricos e Fluviométricos do Estado de São Paulo (ambos em CD-ROM (<http://hidracomp.cth.usp.br>)), o Banco de Dados do Instituto Nacional de Meteorologia – INMET (<http://www.inmet.gov.br>); o Banco de Dados da Fundação Centro Tecnológico de Hidráulica da Universidade de São Paulo – FCTH/USP e o da Faculdade de Engenharia Civil da Universidade de Campinas – FEC/Unicamp.

As áreas das bacias dos rios das Almas e Itapetininga<sup>1</sup>, foram delineadas através das cartas topográficas, em escala 1:50.000, fornecidas pela FCTH e FEC/Unicamp e posteriormente digitalizadas através do aplicativo Auto-Cad R14, originando os mapas das referidas bacias. Nesses mapas foram plotados os respectivos postos pluviométrico, para que neles fossem calculadas as áreas de influências (polígonos) de cada posto selecionado. O método utilizado na determinação dos *fatores de pesos*  $w_i$  correspondentes a cada um dos polígonos foi o *Método dos Polígonos de Thiessen*, que determina a precipitação média na bacia, o qual considera a não-uniformidade da distribuição espacial dos postos e não leva em conta o relevo da bacia (TUCCI, 1993). Esse procedimento foi necessário para o cálculo da chuva média na bacia requerido no programa SMAPm.

---

<sup>1</sup> As bacia do rio Guaporé já possuía calculado os fatores de peso.

O estudo teórico do modelo SMAP (*Soil Moisture Accounting Procedure*) e seu respectivo aplicativo SMAPm v.99 antecedeu a busca de dados, pois a partir de sua estrutura simplificada é que foi construído o modelo de redes neurais equivalentes.

O estudo do software foi realizado aplicando-se os dados relativos aos postos hidrometeorológico referentes a cada uma das quatro bacias selecionadas. Uma análise pormenorizada da estrutura do programa, já descrita no capítulo 4, buscando entender o funcionamento e a articulação de diversas rotinas que o compõem, permitiram estruturar a arquitetura da RNA, visando um melhor desempenho nas simulações.

Os nomes dos arquivos obedeceram ao código utilizado pelo Departamento Nacional de Águas e Energia Elétrica (DNAEE), ou seja, os dois primeiros números correspondem à bacia hidrográfica e os três seguintes indicam o posto. Tomando como exemplo um dos ensaios, o resumo da aplicação para a bacia do rio Amazonas, sub-bacia do rio Madeira (15) é:

Arquivo	15050
UF	MT
Nome do Rio	Rio Guaporé
Ad km <sup>2</sup>	2504 (Área de drenagem, km <sup>2</sup> )
sat	2500 (Capacidade de saturação do solo, mm)
pes	4 (parâmetro de escoamento superficial, ad.)
crec	20 (coeficiente de recarga. ad.)
k	3 (Constante de recessão, mês <sup>-1</sup> )
Tuin	50 (Teor de umidade inicial. ad.)
basin	33. (Vazão básica inicial, m <sup>3</sup> /s)
P	1566 (Chuva)
Es	207 (Escoamento superficial, m <sup>3</sup> /s)
Eb	437 (Escoamento básico, m <sup>3</sup> /s)

Considerando a extensão da série histórica correspondente a cada bacia estudada, foram divididos em intervalos anuais os dados fluviométricos e pluviométricos com fins à calibração e

validação do modelo, conforme **Tabela 5.1**. Para a bacia do rio Itapetininga, dos 18 anos da série histórica, foram divididos quatro arquivos de dados para a calibração e dois para a validação; na bacia do rio das Almas, os nove anos de observação foram divididos em 3 arquivos para calibração e apenas um para a validação; na bacia do rio Guarapiranga, com a maior série histórica do conjunto de bacias, 40 anos de registros, quatro arquivos foram usados para a calibração e dois para validação e, finalmente, a bacia do rio Guaporé, com apenas 4 anos de dados mensais, um arquivo para calibração e outro para validação.

**Tabela 5.1 - SMAP - Divisão dos Períodos de Dados para Simulação**

<i>Rio Itapetininga</i>		<i>Rio das Almas</i>		<i>Rio Guarapiranga</i>		<i>Rio Guaporé</i>	
<i>Bacia</i>							
<i>Período</i>							
<i>Calibração</i>	<i>Validação</i>	<i>Calibração</i>	<i>Validação</i>	<i>Calibração</i>	<i>Validação</i>	<i>Calibração</i>	<i>Validação</i>
1973-1976	1986-1988	1972-1975	1978-1980	1954-1961	1978-1985	1975-1976	1977-1978
1976-1979	1989-1991	1973-1976		1962-1969	1986-1993		
1979-1982		1974-1977		1966-1972			
1982-1985				1970-1977			

Os dados pluviométricos das bacias dos rios Itapetininga e Almas foram extraídos do CD-Rom BcDAEEplu v1.0 (FCTH,1998a). As demais bacias, tiveram seus dados cedidos pelo engenheiro João Eduardo Gonçalves Lopes e pela FCTH/USP. Os postos selecionados para cada bacia estão na **Tabela 5.2**.

**Tabela 5.2 - Postos Pluviométricos Selecionados**

<i>Bacia</i>	<i>Prefixo</i>	<i>Nome</i>
Itapetininga	E5-047	Ferreira das Almas
	E4-028	Usina Batista
	E4-132	Bairro Riberão Bonito
Almas	F5-025	Barreiro
	F5-041	Bairro Cerrado
Guarapiranga	12059	Barragem
Guaporé	59000	Pontes e Lacerda
	58004	Alto Jauru

Os dados fluviométricos e evaporimétricos para as bacias dos rios Itapetininga e Almas foram extraídos do CD-Rom BcDAEEflu v1.0 (FCTH,1998b) e cedidos pela FCTH/USP, respectivamente. Para as demais bacias os dados referentes a estas variáveis também foram cedidos pelo engenheiro João Eduardo Lopes e pela FCTH. Os postos selecionados para cada bacia estão na **Tabela 5.3**.

**Tabela 5.3 – Postos Fluviométricos e Evaporimétricos Selecionados**

<i>Bacia</i>	<i>Área (km²)</i>	<i>Posto Fluviométrico</i>		<i>Posto Evaporimétrico</i>
		<i>Prefixo</i>	<i>Nome</i>	<i>Nome</i>
Itapetininga	1524	5E-006	Porto Velho	Jurumirim
Almas	495,64	5E-004	Bairro Cerrado	Jurumirim
Guarapiranga	631	62290	Barragem	Jurumirim
Guaporé	2504	15030	Pontes e Lacerda	Diamantino

### 5.3.2 *Modelo de RNA's*

Os dados utilizados para a simulação do modelo de RNA, com topologia constituída por uma camada intermediária e treinamento do tipo supervisionado, foram os mesmos aplicados no modelos SMAPm. A seguir, estão estruturadas todas as informações que constituem a simulação através da modelagem por redes neurais:

1. *Conjunto de dados de entrada-saída (par padrão),  $(\mathbf{x}_k, \mathbf{d}_k)_{k=1}^N$ ;*

- ✓ *Caso 1:*  $x_k$  = precipitação (P, mm/mês);  $d_k$  = vazão(Q, m<sup>3</sup>/s);
- ✓ *Caso 2:*  $x_k^1$  = escoamento superficial (Es, m<sup>3</sup>/s);  $x_k^2$  = escoamento básico (Eb, m<sup>3</sup>/s) e  $d_k$  = vazão(Q, m<sup>3</sup>/s);
- ✓ *Caso 3:*  $x_k^1$  = volume reservatório superficial (R<sub>sup</sub>, m<sup>3</sup>/s);  $x_k^2$  = volume de reservatório subterrâneo (R<sub>sub</sub>, m<sup>3</sup>/s) e  $d_k$  = vazão(Q, m<sup>3</sup>/s);
- ✓ *Caso 4:*  $x_k^1$  = precipitação no Posto 1 (P1, mm/mês);  $x_k^2$  = precipitação no Posto 2 (P2, mm/mês) e  $d_k$  = vazão(Q, m<sup>3</sup>/s).

Os valores de N (número total de pares padrão ou exemplos, contidos no conjunto de treinamento) são variáveis de acordo com o período de dados disponíveis para cada bacia e estão registrados na **Tabela 5.4**.

As séries de entrada e saída identificadas foram classificadas como *atributos com valores reais*<sup>2</sup> por tratarem de variáveis hidrológicas. Nesse caso, os dados foram normalizados de acordo com o operador que os mapearam no intervalo [-1,+1].

2. *Função Objetivo a ser Minimizada:* Erro Médio Quadrático, (*Mean Squared Error – MSE*);
3. *Função de Ativação:* é função *tangente hiperbólica* do tipo *sigmoïdal*, sendo a mesma para todos os neurônios;
4. *Algoritmo de Treinamento:* Algoritmo de Gradiente Conjugado Escalonado (GCE);
5. *Dimensão da RNA :*

---

<sup>2</sup> Os valores de entrada e saída devem obedecer representações, segundo os seguintes tipos: atributos com valores reais; atributos com valores inteiros; atributos ordinais; atributos nominais e atributos com valores inexistentes.

- ✓ Fixa: 1 camada de entrada, 1 camada intermediária e 1 camada de saída. O número de neurônios da camada intermediária e o número de parâmetros livres dependem do treinamento de cada bacia simulada. Às camadas intermediárias e de saída foram atribuídos limiares e estes foram computados juntamente com os pesos no total de parâmetros livres da rede.
  - ✓ Como o treinamento da rede é realizado por um algoritmo de segunda ordem ela deve ser submetida a uma reinicialização de cada treinamento referente a cada iteração, considerando-se problemas quadráticos (SILVA, 1998), pois em sua maioria esses métodos são deduzidos.
6. *Conjunto Inicial de Pesos*: a inicialização dos pesos é feita por geração aleatória, com distribuição uniforme no intervalo  $[-0,1, 0,1]$ , através da função auxiliar **Inic.m** (**Anexo D**);
  7. *Método da Taxa de Aprendizagem*: Método da Minimização da Função;
  8. *Processo Iterativo para o Treinamento da Rede*: método em Lote ou Batelada;
  9. *Processo de Validação Cruzada Aplicado*: foi considerado somente um conjunto de dados para treinamento e outro conjunto de dados para validação, objetivando uma avaliação sistemática do desempenho da rede. Apesar da série dos dados da bacia do rio Guarapiranga ser extensa, as demais são pequenas para que se proceda a uma divisão em três conjuntos – treinamento, validação e teste;
  10. *Quanto ao particionamento dos dados a serem atribuídos a cada conjunto*: admitiu-se que o conjunto de validação representasse de 20 a 10% do conjunto de treinamento, conforme a extensão da série.
  11. *Critério de Parada dos Procedimentos de Validação Cruzada*: diante dos diversos critérios existentes, optou-se por aplicar um limite no número de épocas (passos) durante o treinamento e a validação da rede. O limite estabelecido foi verificado pelo valor mínimo do erro da função objetivo, alcançada através do gráfico Superfície de Erro X Épocas.

12. *Tempo de Treinamento*: o tempo de processamento médio para treinamento da rede variou em torno de 5 a 15 segundos em um computador do tipo PC PentiumIII com 128MB de memória RAM.

A partir das séries históricas de vazões e chuvas, foram selecionados, para cada bacia, os períodos correspondentes aos processos de calibração e validação do modelo – **Tabela 5.4**.

**Tabela 5.4 -RNA - Divisão dos Períodos de Dados para Simulação**

BACIA							
<i>Rio Itapevinga</i>		<i>Rio das Almas</i>		<i>Rio Guarapiranga</i>		<i>Rio Guaporé</i>	
PERÍODO							
<i>Calibração</i>	<i>Validação</i>	<i>Calibração</i>	<i>Validação</i>	<i>Calibração</i>	<i>Validação</i>	<i>Calibração</i>	<i>Validação</i>
1973-1986	1987-1991	1972-1977	1978-1980	1954-1983	1984-1993	1975-1977	1978

Definida a topologia da rede, estruturou-se o fluxograma para quatro casos, excludentes entre si, a serem objeto de estudo do modelo proposto: **Caso 1 (Figura 4.5)**; **Caso 2 (Figura 4.6)**; **Caso 3 (Figura 4.7)** e **Caso 4 (Figura 4.8)**.

Quanto ao modo de treinamento, o modelo de RNA proposto inicialmente usava um algoritmo de otimização de primeira ordem para o treinamento da rede - aplicava-se o algoritmo *backpropagation*. Partindo de uma série de investigações quanto à alternativa de outros algoritmos de treinamento que apresentassem algumas vantagens, com vista a melhorar a performance da rede na aplicação de séries temporais, foi que se propôs realizar algumas mudanças na metodologia seguida inicialmente para o treinamento da RNA.

A busca por outros algoritmos de treinamento de rede que apresentassem um melhor desempenho, em relação aos métodos de primeira ordem, foi o ponto de partida. Assim, foi testado um algoritmo de treinamento de segunda ordem denominado *Gradiente Conjugado Escalonado* – GCE, (BISHOP, 1997), desenvolvido por MOLLER (1993). O professor Dr. Fernando José Von Zuben da Faculdade de Engenharia Elétrica e de Computação da Unicamp, empregou este algoritmo, num programa computacional de treinamento de redes neurais em linguagem MATLAB, denominado *Moller* (Anexo D). Foram executadas algumas modificações

nesse programa objetivando atenuar a sua adaptação ao sistema hídrico formulado para os quatro tipos de estudo de caso, assim como foram inseridas algumas rotinas para a composição do programa para esse estudo de caso (Anexos A, B, C, E, F).

Com esse método o desempenho da rede foi superior ao método anterior, em relação à redução do tempo de treinamento, menor erro quadrático entre os dados observados e calculados e menos parâmetros (pesos) a serem treinados. Por isso, o método foi escolhido para o treinamento da rede como estudo de caso para as bacias selecionadas. O algoritmo foi escrito em linguagem MATLAB<sup>®</sup> v.5.2.

Deve-se estabelecer uma série de observações (período anual da série mensal) para as fases de calibração e validação dos modelos. Esta série de dados deve ter uma extensão maior para a calibração do que para a validação.

### **5.3.3 Avaliação Estatística dos Resultados**

Na modelagem chuva-vazão, as fases que envolvem a identificação de um modelo são (HZU, GUPTA e SOROOSHIAN, 1995):

1. seleção dos dados de entrada e saída adequados à calibração e validação;
2. seleção de uma estrutura do modelo e estimação de seus parâmetros, e
3. validação do modelo identificado.

Nesse estudo de caso são comparados os desempenhos de três estruturas de modelos diferentes em relação a sua capacidade de representar o processo chuva-vazão da bacia.

Foram selecionadas as seguintes estruturas de modelo:

1. Modelos teórico de sistema não-linear: modelo de redes neurais *feedforward* com três camadas;
2. Modelos mistos: aplicando (1) e (3) e
3. Modelo conceitual determinístico: modelo *Soil Moisture Accounting Procedure* (SMAP).

Após a execução das duas primeiras fases do processo de identificação dos parâmetros dos modelos, para um período de observação de dados mensais de descarga, precipitação e evaporação, o próximo passo é a escolha do modelo que consiste em validar ou verificar se os modelos reproduzem os dados adequadamente.

A avaliação dos resultados é conduzida pela representação gráfica da variabilidade temporal (hidrogramas mensais) através do cálculo de parâmetros estatísticos indicativos dos valores observados e calculados pelo modelo (média aritmética, desvio padrão, correlação linear e variância.).

Dentre os métodos existentes de verificação do modelo o nível de ajuste de uma calibração de dados é avaliado aplicando-se três dos métodos mais tradicionais de análises estatísticas dos resíduos: erro da raiz média quadrática (ERMQ), *critério de informação A* (AIC) ou *critério de Akaike* (AKAIKE, 1974) e *critério de informação B* (BIC) ou *Baysiano*, (SCWARZ, 1976).

O Critério de Informação de Akaike é também chamado de Procedimento MAICE (*minimum Akaike information criterium estimation*), AKAIKE, (1974) e MORETTIN e TOLLOI (1985). Este critério incorpora o princípio da parcimônia sugerido por BOX e JENKINS (1976), segundo o qual o modelo será considerado ideal quando, utilizando-se do mínimo número de parâmetros, possa apresentar o máximo de informação. A expressão mais simplificada deste critério é a seguinte:

$$AIC = N \log \hat{\sigma}_a^2 + 2k \quad (5.1)$$

Em que  $N$  é o número de observações,  $\log$  denota o logaritmo natural,  $\hat{\sigma}^2$  é a variância e  $k$  é o número de parâmetros envolvidos no modelo. No caso da existência de vários modelos ou de um mesmo modelo com opção de várias estruturas, seleciona-se aquele que apresenta o mínimo valor obtido pelo critério de AIC.

O cálculo da variância  $\hat{\sigma}^2$  de uma amostra  $n$  é dado por:

$$\sigma^2 = \frac{n \sum x^2 - (\sum x)^2}{n(n-1)} \quad (5.2)$$

O valor de  $k$  é determinado como:

- Para o modelo de RNA, passa a ser o número de pesos sinápticos da rede.
- Para o caso do modelo SMAP, o número de parâmetros calibrados.

O Critério de Informação Baysiano é expresso por (SCHAWRS, 1978):

$$\text{BIC} = N \log \hat{\sigma}_a^2 + k \log N \quad (5.3)$$

Em que  $N$  é o número de observações,  $\log$  denota o logaritmo natural,  $\hat{\sigma}^2$  é a variância e  $k$  é o número de parâmetros envolvidos no modelo.

Nesse critério a seleção do modelo é feita a partir do valor mínimo obtido no cálculo de BIC. Em caso de empate no uso de outro critério, por exemplo, AIC, então BIC passa a ser usado como critério decisivo.

Os resultados calculados das estatísticas AIC e BIC para cada modelo mostram aqueles mais prováveis de serem selecionados para cada situação simulada na bacia em estudo.

A escolha da melhor estrutura de rede será feita considerando os dois menores resultados correspondentes aos critérios AIC e BIC, sendo que o BIC deverá ser usado como critério

decisivo. A melhor estrutura de modelo será selecionada dentre aquelas que obtiverem o menor valor para cada critério.

Dando prosseguimento à avaliação da performance dos dois modelos escolhidos; SMAP e o modelo baseado em de redes neurais, respectivamente, os resultados obtidos tanto no processo de calibração quanto no processo de validação dos modelos, são comparados usando métodos estatísticos, tais como: Erro Padrão de Estimativa (*Root-mean-square error*, RMSE); Correlação Estatística (*correlation statistic*, CORR=  $\rho_{X,Y}$ ); Erro Percentual da Vazão Máxima (*percent error of maximum flow*, %MF) e Correlação Estatística (*correlation statistic*, CORR=  $\rho_{X,Y}$ ).

A exemplificação a seguir é construída com os resultados dos cálculos estatísticos, aplicados aos produtos de calibração e de validação para todas as alternativas estruturais de redes das  $n$  combinações de modelos propostos.

As expressões para os cálculos estatísticos escolhidos para este estudo são:

- Erro padrão de estimativa (*Root-mean-square error*, RMSE):

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n-1}} \quad (5.4)$$

em que,  $e_i = Q_{\text{obs}}^i - Q_{\text{cal}}^i$ ;  $n$  é o número da amostra,  $Q_{\text{obs}}^i$  é vazão observada no instante  $i$ ,

$Q_{\text{cal}}^i$  é a vazão calculada no instante  $i$ , e o

$$\text{denominador} \begin{cases} (n-1) & \text{se } n \geq 29 \\ n & \text{se } n < 29 \end{cases} .$$

O valor ótimo desta medida estatística de variância residual é 0,0.

- Erro percentagem de volume (*percent volume error, %VE*)

$$\%VE = \frac{\sum_{i=1}^n (Q_{obs}^i - Q_{calc}^i)}{\sum_{i=1}^n Q_{obs}^i} \quad (5.5)$$

Este resultado estatístico mede o erro percentual em volume sobre as hidrógrafas observadas e simuladas com relação ao período dos dados. O melhor resultado é 0,0. Valores positivos indicam sobrestimação, e negativos subestimação.

- Erro percentual da vazão máxima (*percent error of maximum flow, %MF*)

$$\%MF_i = \frac{\Delta_i}{Q_{obs\ i}} \times 100, \quad i = 1, \dots, n \quad (5.6)$$

$$\overline{MF} = \frac{\sum_{i=1}^n MF_i}{n}, \% \quad (5.7)$$

Em que:  $n$  = número de anos,

$$O_{obs\ i} = Q_{max} \text{ de cada ano da série, e} \quad (5.8)$$

$$\Delta_i = \text{desvio} = (Q_{max\ obs} - Q_{max\ cal}) \text{ em cada ano} \quad (5.9)$$

O resultado estatístico mede o erro percentual correspondente à vazão máxima (vazão de pico) dos dados registrados. O melhor resultado é 0,0. Valores positivos indicam sobrestimação e negativos subestimação.

- Correlação estatística (*correlation statistic*,  $\text{CORR} = \rho_{X,Y}$ )

$$\rho_{X,Y} = \frac{\text{Cov}(X,Y)}{\sigma_X \times \sigma_Y} \quad (5.10)$$

sendo:  $-1 \leq \rho_{X,Y} \leq 1$  e

$$\sigma_x^2 = \frac{1}{n} \sum (X_i - \mu_x)^2 \quad (5.11)$$

$$\sigma_y^2 = \frac{1}{n} \sum (Y_i - \mu_y)^2 \quad (5.12)$$

$$\text{Cov} = \frac{1}{n} \sum_{i=1}^n (x_i - \mu_x)(y_i - \mu_y) \quad (5.13)$$

Essa medida estatística indica o grau de correlação linear entre as vazões observadas e simuladas. O valor ótimo é 1,0.

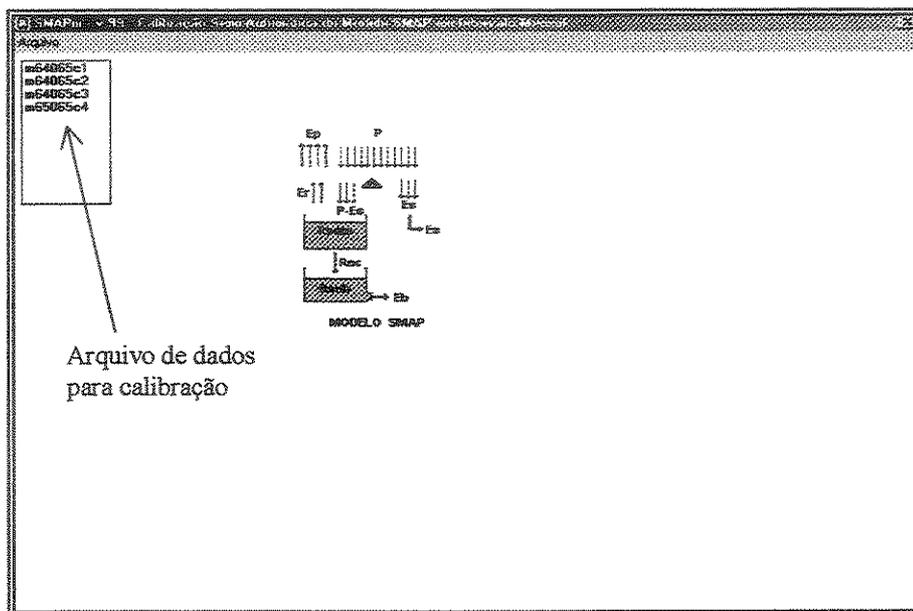
A *Correlação* serve para determinar se dois conjuntos de dados se movem juntos, isto é, se os grandes valores de um conjunto estão associados aos grandes valores do outro (correlação positiva), se os pequenos valores de um conjunto estão associados aos pequenos valores do outro (correlação negativa) ou se os valores dos dois conjuntos não se relacionam (correlação próxima a zero).

## 5.4 Simulação do Modelo SMAPm

Sem modificações de sua estrutura original, serão realizados vários ensaios para se calibrar e validar a série de vazões. Uma simulação é realizada preliminarmente com os parâmetros definidos conforme os dados fornecidos no arquivo de entrada. A seguir, utilizando a análise de sensibilidade, inicia-se o processo de Pesquisa Global realizado pelo Método de Busca Direta sem limites a múltiplas variáveis, no qual, com vista a refinar os parâmetros obtidos, aplica-se o algoritmo de ROSEMBROCK (1960) e, posteriormente, ajustando-se os parâmetros de forma manual como forma de melhorar as hidrógrafas.

### 5.4.1 Programação

Os arquivos de dados do programa (Anexo G) são construídos de acordo com o tamanho da série histórica procurando-se executar grupos para calibração e validação com intervalos temporais entre 2 e 4 anos de dados. A inicialização do ensaio é feita selecionando-se no aplicativo a opção para o intervalo de discretização mensal do tempo de simulação e, posteriormente, no menu principal aciona-se a opção calibrar. Na seqüência, no menu Arquivo, escolhe-se a opção Abre e a seguir o arquivo de dados da bacia a ser calibrado ou validado (**Figura 5.3**):



*Figura 5.3 – SMAPm - Seleção do Arquivo*

É inicializado o processo de Pesquisa Global através da análise de sensibilidade dos parâmetros (Figura 5.4).

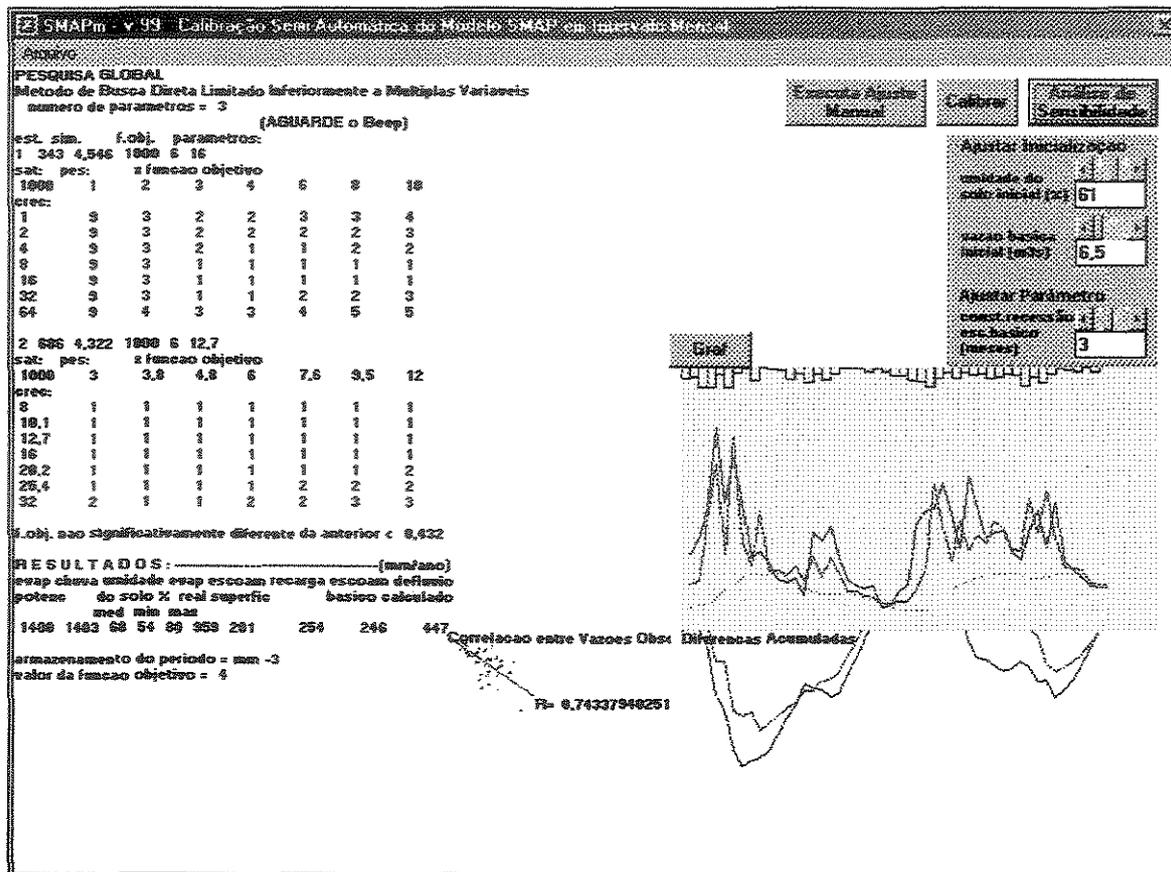


Figura 5.4 – SMAPm - Procedimento de Análise de Sensibilidade

É solicitado o procedimento de calibração do modelo (Figura 5.5).

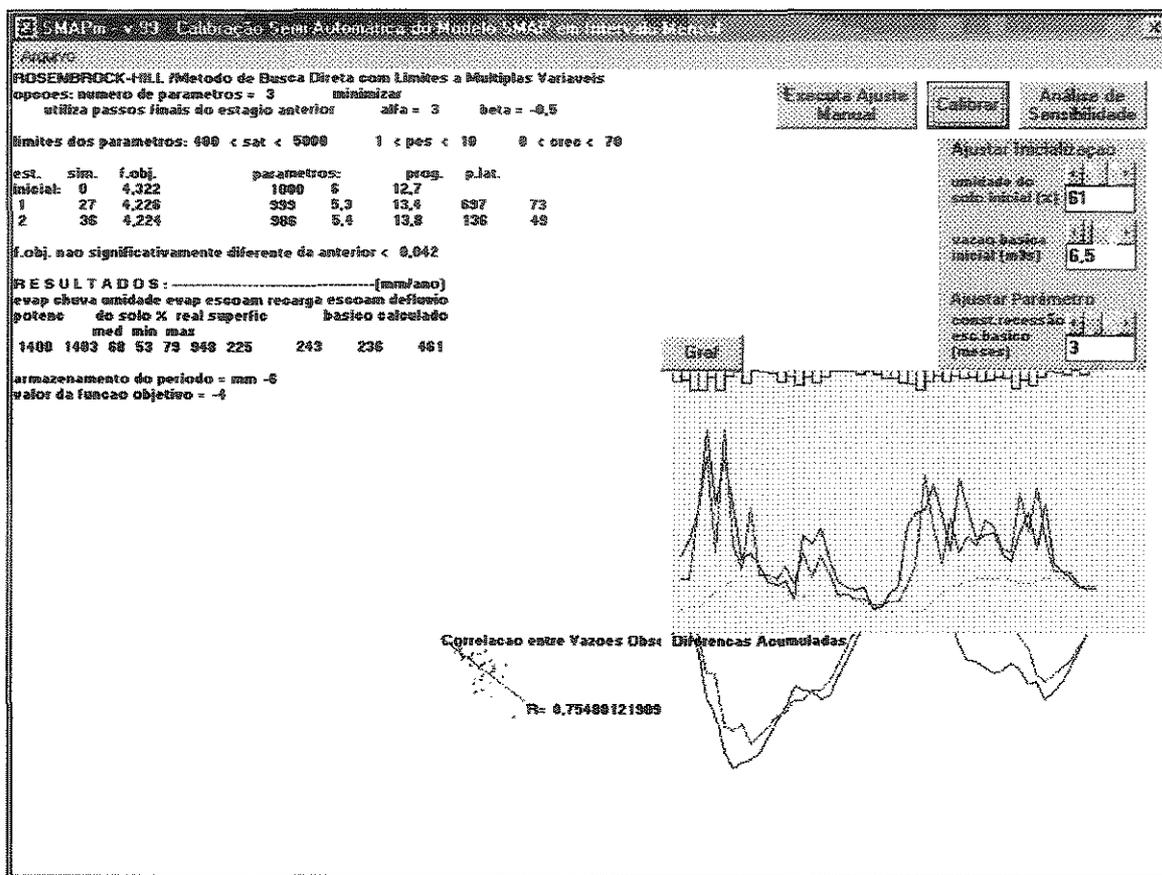


Figura 5.5 – SMAPm - Procedimento de Calibração

Na seqüência, é necessária a atribuição manual (não automática) do ajuste das variáveis de inicialização (umidade do solo inicial e vazão básica) do parâmetro  $k$  (constante de recessão) – quadro extremo à direita -, dos parâmetros de capacidade de saturação do solo, escoamento superficial e recarga subterrânea, por meio de controles constantes no quadro de Ajuste Manual (Figura 5.6). Neste procedimento a performance do modelo contará com a experiência do usuário na verificação dos melhores valores de ajuste. Para uma melhor calibração do modelo sugere-se inicialmente, deixar a curva de escoamento básico com um desenvolvimento homogêneo ao longo da hidrógrafa e que as vazões iniciais estejam as mais próximas possíveis uma das outras.

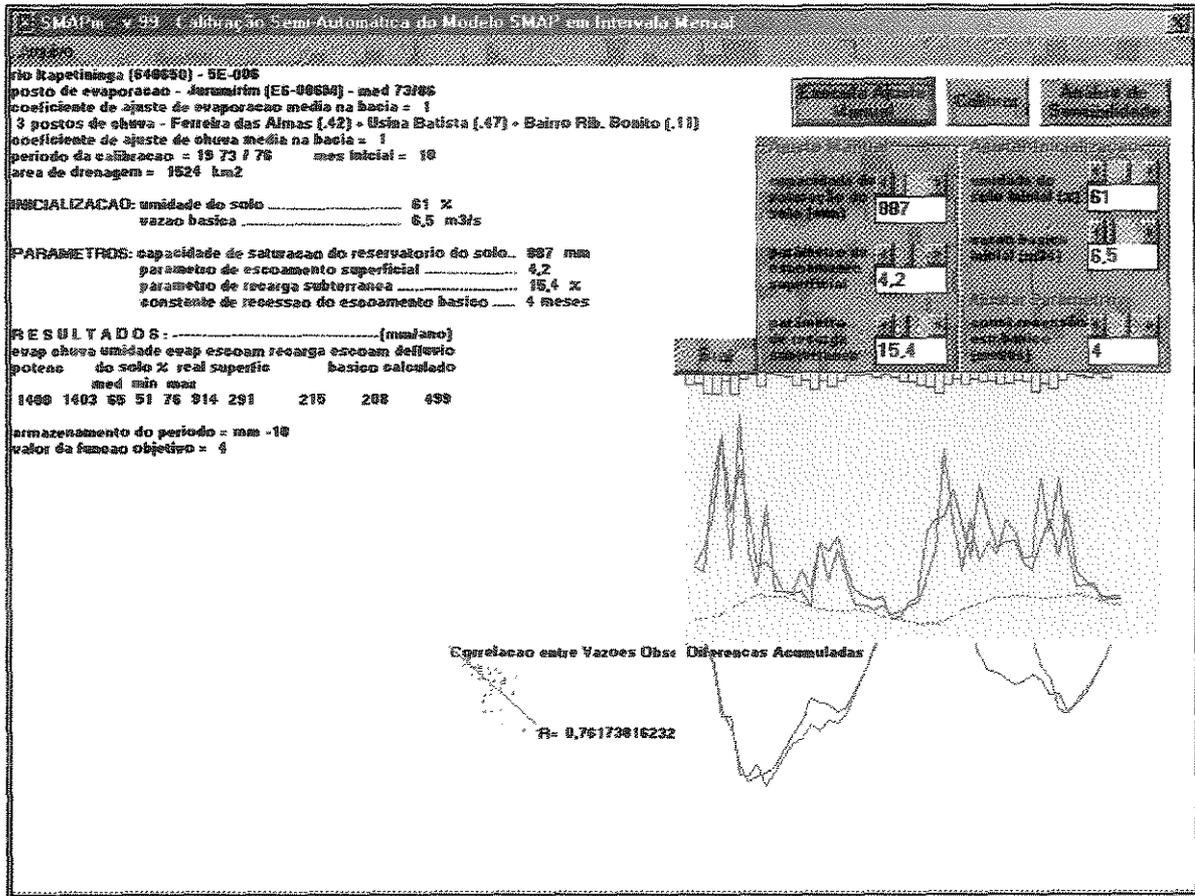


Figura 5.6 – SMAPm - Ajuste Manual dos Parâmetros e Variáveis de Inicialização

Cada vez que um valor for alterado deve-se solicitar a execução do Ajuste Manual. Quando forem encontrados os valores que tenham se ajustado às curvas, a opção é gravar e imprimir os resultados gerados através do aplicativo Bloco de Notas.

### 5.4.2 Resultados

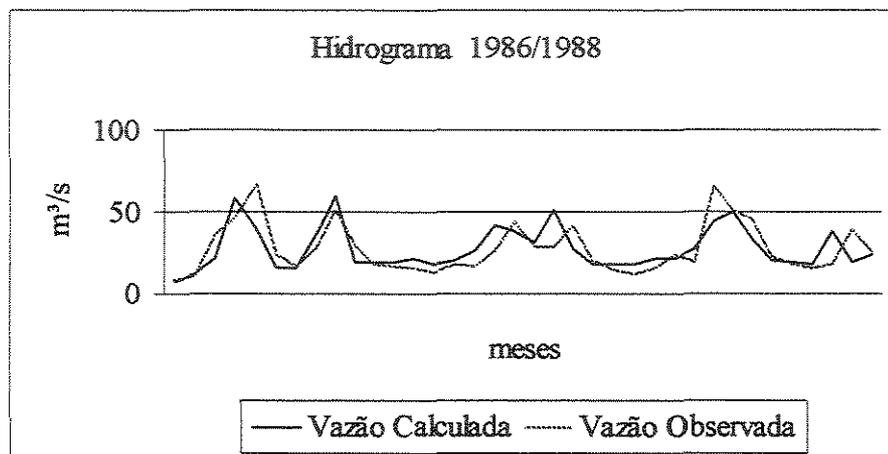
No Anexo H, encontram-se os resultados registrados nos arquivos gravados, ao término de cada validação, na simulação das respectivas bacias. Os resultados das vazões simuladas no processo de validação do SMAPm v.99 e das vazões observadas nos postos fluviométricos para

cada bacia estão no Anexo I. A seguir serão apresentados os respectivos hidrogramas das vazões do período de validação.

a) **Bacia do Rio Itapetininga**

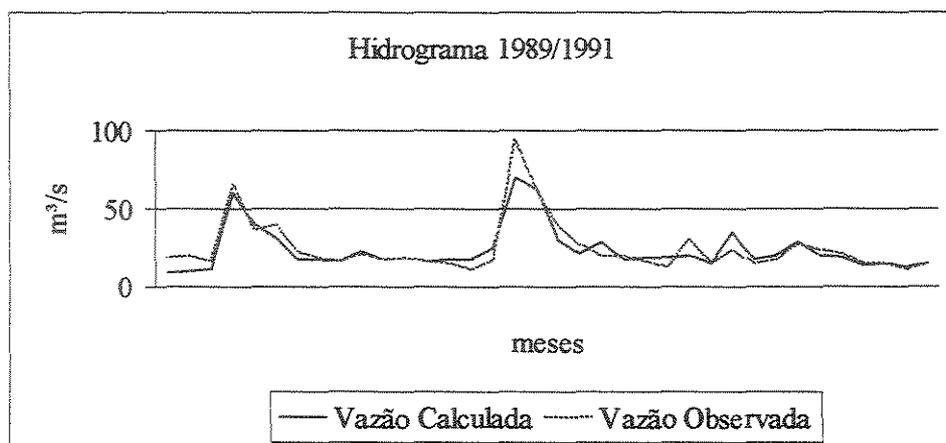
- Arquivo m64065v1

**Gráfico 5.1 – Bacia do Rio Itapetininga – Hidrograma das Vazões Médias Mensais ( $m^3/s$ ) – Validação 1 – Período 1986 a 1988**



- Arquivo m64065v2

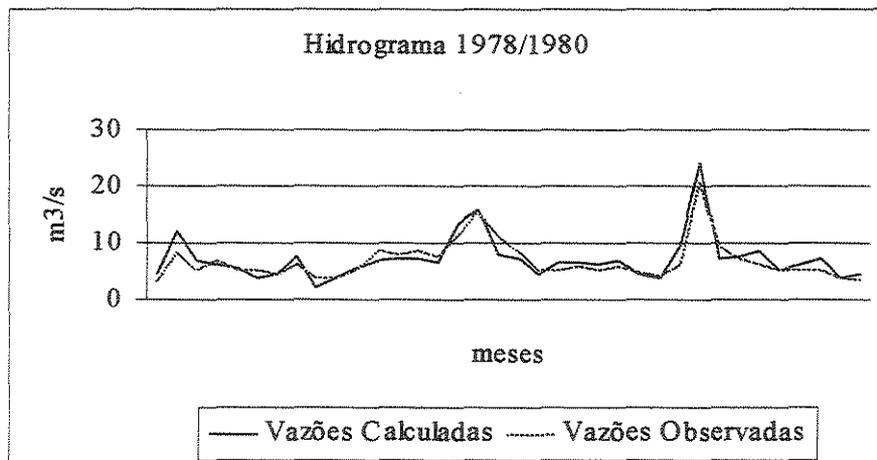
**Gráfico 5.2– Bacia do Rio Itapetininga – Hidrograma das Vazões Médias Mensais ( $m^3/s$ ) – Validação 2 – Período 1989 a 1991**



**b) Bacia do Rio das Almas**

- Arquivo m64035v1

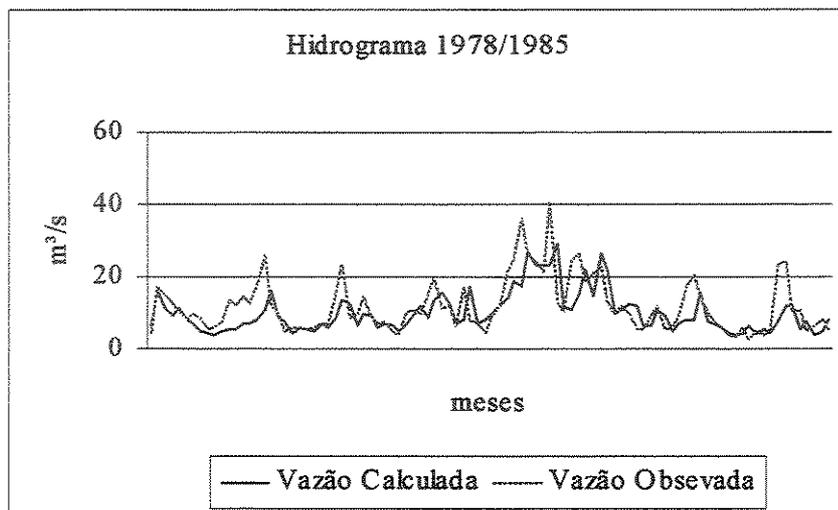
**Gráfico 5.3– Bacia do Rio das Almas – Hidrograma das Vazões Médias Mensais ( $m^3/s$ ) – Validação 1 – Período 1978 a 1980**



**c) Bacia do Rio Guarapiranga**

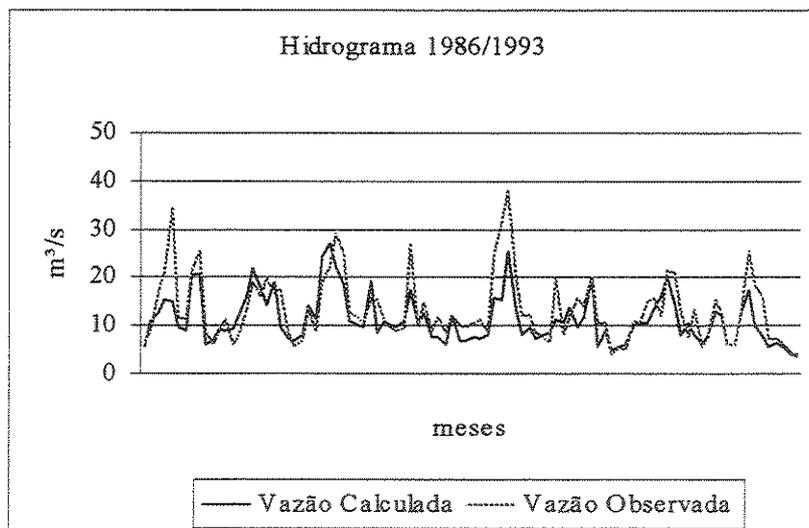
- Arquivo m6229v1

**Gráfico 5.4– Bacia do Rio Guarapiranga – Hidrograma das Vazões Médias Mensais ( $m^3/s$ ) – Validação 1 – Período 1978 a 1985**



- Arquivo m6229v2

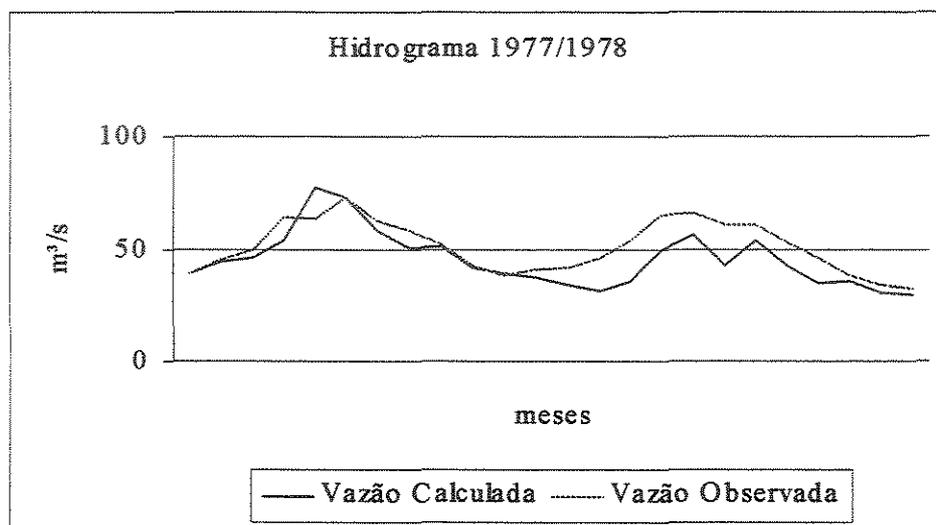
**Gráfico 5.5– Bacia do Rio Guarapiranga – Hidrograma das Vazões Médias Mensais ( $m^3/s$ ) – Validação 2 – Período 1986 a 1993**



**d) Bacia do Rio Guaporé**

- Arquivo ml5051vl

**Gráfico 5.6– Bacia do Rio Guaporé – Hidrograma das Vazões Médias Mensais (m<sup>3</sup>/s) – Validação 1 – Período 1977a 1978**



## 5.5 Simulação do Modelo em RNA's

A modelagem utilizando a técnica de redes neurais artificiais foi realizada com o auxílio dos estudos teóricos e a aplicação do software MATLAB<sup>®</sup> v.5.2 for Windows.

O treinamento e o teste do modelo de RNA foram executados considerando-se diversas topologias – variando-se o número de neurônios na camada intermediária e fixando-se, em uma, a camada intermediária - de rede e observando-se o número de iterações máximas para pequenas variações dos erros quadráticos. Assim sendo, as topologias selecionadas para a discussão dos resultados foram escolhidas com base no menor erro quadrático e no menor número de neurônios na camada intermediária, registrados tanto no treinamento como na validação da simulação. A

seguir detalhamos os passos que conduziram ao treinamento e ao teste da rede, para as bacias propostas e seus respectivos casos de simulação.

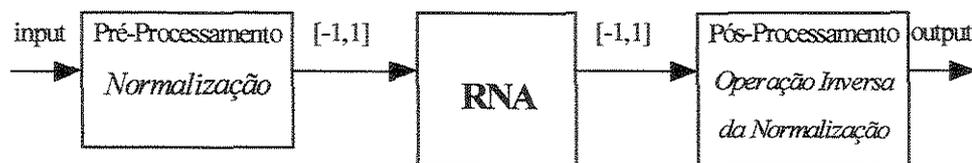
### 5.5.1 Programação

Na metodologia adotada para o processamento dos resultados, inicialmente procurou-se estabelecer séries hidrológicas cujos dados fossem consistentes e de extensão de registros temporais mensais consideráveis. Conforme a bacia simulada estabeleceu-se o mesmo tamanho da série histórica para todos os casos simulados – Caso1, 2, 3 e 4 - dividindo-a para o treinamento e validação da simulação. Os arquivos foram criados no aplicativo Bloco de Notas for Windows® e salvos com extensão **dat** registrando-se em linha, na primeira coluna o ano e nas demais colunas os registros mensais, iniciando pelo primeiro mês do ano hidrológico.

Os passos a seguir indicam a metodologia de processamento adotada.

- *Passo1*: Normalização (Pré-processamento) dos dados de entrada para treinamento e validação da RNA.

Foi desenvolvida uma metodologia de cálculo para treinamento e validação de RNA, na qual procurou-se inicialmente pré-processar os dados de entrada na rede, antes de seu treinamento e posteriormente pós-processar os resultados calculados (**Figura 5.7**).



*Figura 5.7 - Desenho esquemático do uso de pré-processamento e pós-processamento dos dados em conjunto com o mapeamento de RNA*

- 
- ✓ Os dados serão normalizados entre o intervalo (range) de [-1,1]. O programa que executa este cálculo é o **Normalisa.m**, (Anexo C) considerando cada um dos quatro casos simulados;
  - ✓ Para o Caso1, a entrada serão os arquivos de dados observados das vazões médias mensais ( $m^3/s$ ) e das precipitações médias mensais da bacia, respectivamente;
  - ✓ Para o Caso2, a entrada serão os arquivos de dados calculados das vazões dos escoamentos superficial ( $E_s$ ) e básico ( $E_b$ ), respectivamente;
  - ✓ Para o Caso3, a entrada serão os arquivos de dados calculados dos volumes dos reservatórios superficial ( $R_{solo}$ ) e subterrâneo ( $R_{sub}$ ), respectivamente;
  - ✓ Para o Caso 4, quando houver quantidade de postos pluviométricos em número superior ou igual a dois, serão dois ou mais arquivos correspondendo à precipitação média mensal ( $m^3/s$ ) de cada posto da bacia ;
  - ✓ As saídas normalizadas estão divididas em dois arquivos, um que será a entrada de dados para treinamento da rede e outro que será a entrada para teste ou validação da rede.
- *Passo 2: Treinamento da Rede Neural Artificial*
    - ✓ O treinamento será realizado através do programa **moller.m** (Anexo D). Considerando cada cenário simulado o programa calcula as vazões, os erros médios percentuais e o erro quadrático entre vazões observadas e calculadas, bem como o desempenho da rede,
    - ✓ O dados das vazões treinadas encontram-se normalizados e deverão passar por pós-processamento para retornarem aos seus valores reais.
  - *Passo 3: Teste da Rede Neural Artificial*

- ✓ O teste será realizado através do programa **Testarn1.m** (Anexo E) para verificar o desempenho da rede treinada. Considerando cada cenário simulado, o programa calcula as vazões, os erros médio percentual e quadrático entre vazões observadas e calculadas, bem como o desempenho da rede;
  - ✓ Para a verificação do desempenho da rede para os dados de teste, o programa **Testarn.m** (Anexo F) apresentará os resultados das vazões calculadas e os erros percentual e quadrático,
  - ✓ As séries vazões testadas encontram-se normalizada e deverão passar por pós-processamento para retornarem aos seus valores reais.
- *Passo 4: Pós-processamento dos dados Treinados e Testados (Validados)*
    - ✓ Para cada conjunto de dados, relativos ao caso simulados, serão realizados pós-processamentos em que os valores serão revertidos aos correspondentes valores reais. Esse procedimento é feito no programa dentro dos programas. **Testarn1.m** para os dados de treinamento e **Testarn.m** para os dados testados.
  - *Passo 5: Montagem das tabelas com os resultados finais para treinamento e teste da RNA*

Serão montadas tabelas referentes a cada caso e seus respectivos resultados de acordo com a topologia selecionada. A partir destas tabelas os procedimentos de as análises estatísticas dos resultados serão inicializados.

### 5.5.2 *Resultados*

Para este ensaio, consideramos uma rede *feedforward* com 3 camadas de neurônios, na qual, de acordo com o caso em estudo, ocorre uma variação de neurônios tanto na camada de

entrada (conforme o caso de estudo) como na camada intermediária, permanecendo sempre um neurônio para a camada de saída.

A seguir são apresentados os hidrogramas das simulações validadas, de acordo com a bacia em estudo. Os resultados calculados das vazões encontram-se no Anexo I.

### 5.5.2.1 Bacia do Rio Itapetininga

Foram selecionadas as topologia, segundo cada caso, com base nos menores resultados dos erros quadráticos calculados na simulação. Os resultados desses erros para a calibração e validação dos modelos estão na **Tabela 5.5**.

**Tabela 5.5 – Bacia do Rio Itapetininga – Calibração e Validação: Erro Quadrático**

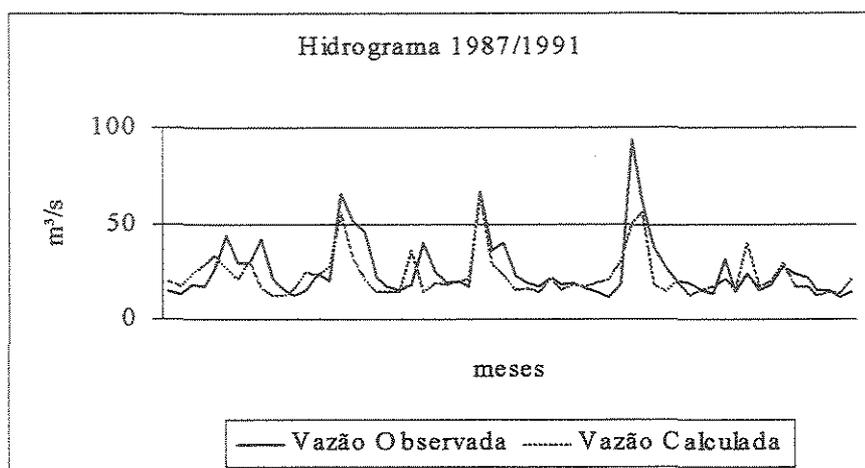
<i>Bacia</i>		<i>Rio Itapetininga</i>							
<i>Número de Iterações = 3000</i>		<i>Calibração</i>				<i>Teste</i>			
<i>Topologia</i>		<i>(1,3,1)</i>	<i>(1,7,1)</i>	<i>(2,3,1)</i>	<i>(2,7,1)</i>	<i>(1,3,1)</i>	<i>(1,7,1)</i>	<i>(2,3,1)</i>	<i>(2,7,1)</i>
Caso1		3,6756	3,7532			1,3454	1,4663		
Caso2		1,2621	1,2560			0,8763	0,9853		
Caso3				0,9587	0,8335			0,6983	0,9216
Caso4				3,4859	2,5032			2,1379	3,8885

Os resultados encontrados para as vazões calculadas neste ensaio, estão resumidos nas tabelas abaixo:

**A. Caso 1**

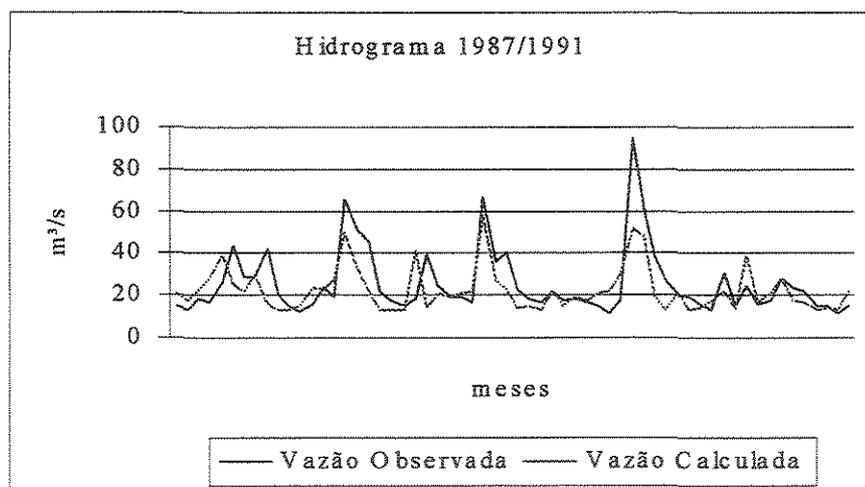
- Topologia (1,3,1)

**Gráfico 5.7– Bacia do Rio Itapetininga – Casol - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (1,3,1)- – Período 1987 a 1991**



- Topologia (1,7,1)

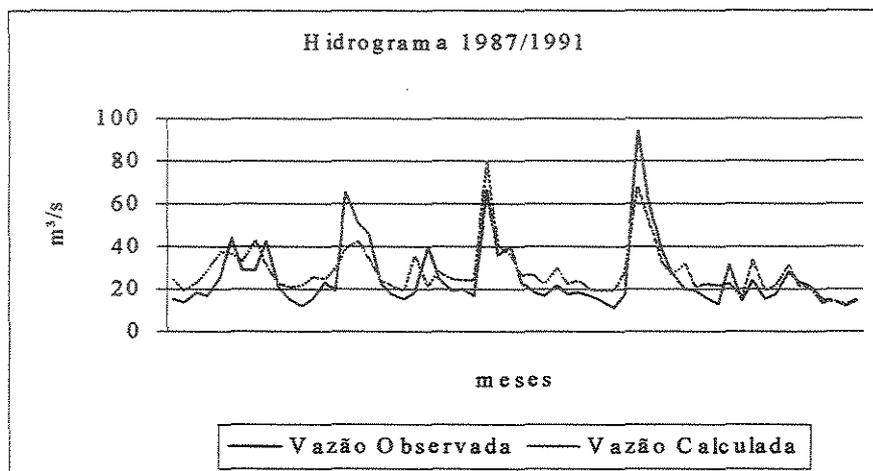
**Gráfico 5.8– Bacia do Rio Itapetininga – Casol - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (1,7,1)- – Período 1987 a 1991**



**B. Caso 2**

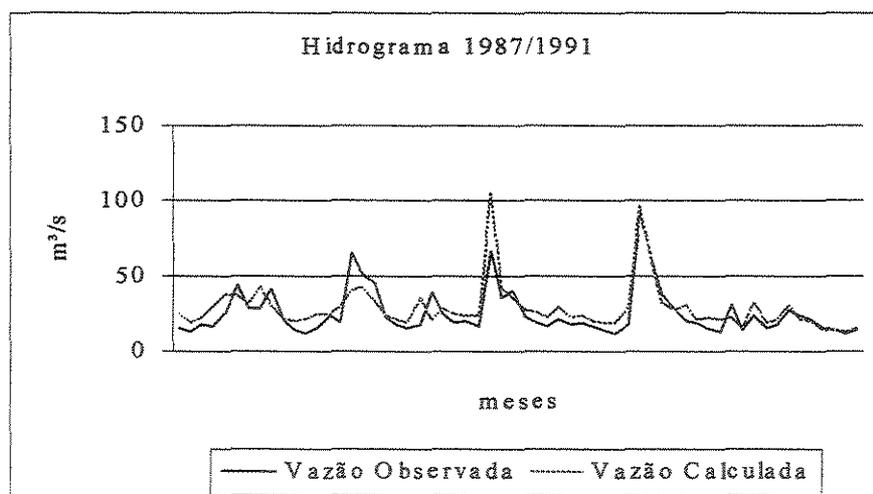
- Topologia (1,3,1)

**Gráfico 5.9– Bacia do Rio Itapetininga – Caso2 - Hidrograma das Vazões Médias Mensais (m<sup>3</sup>/s) – Validação Topologia (1,3,1)- – Período 1987 a 1991**



- Topologia (1,7,1)

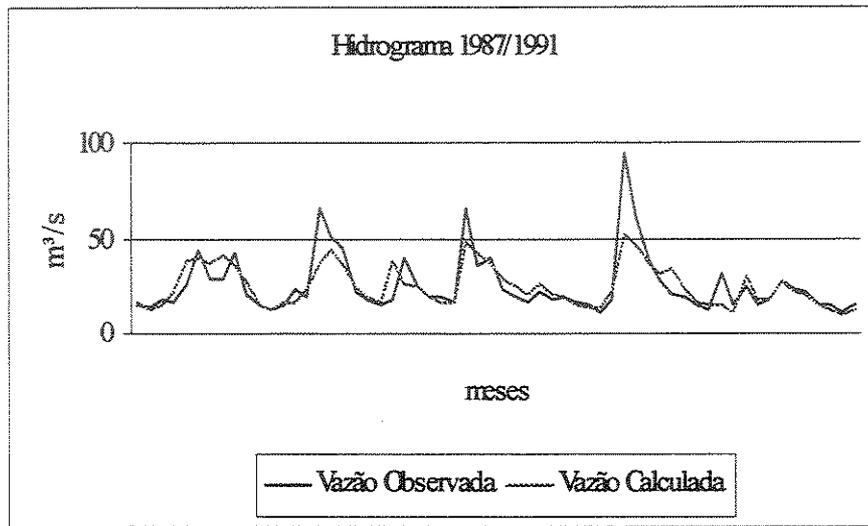
**Gráfico 5.10 – Bacia do Rio Itapetininga – Caso2 - Hidrograma das Vazões Médias Mensais (m<sup>3</sup>/s) – Validação Topologia (1,7,1) – Período 1987 a 1991**



**C. Caso 3**

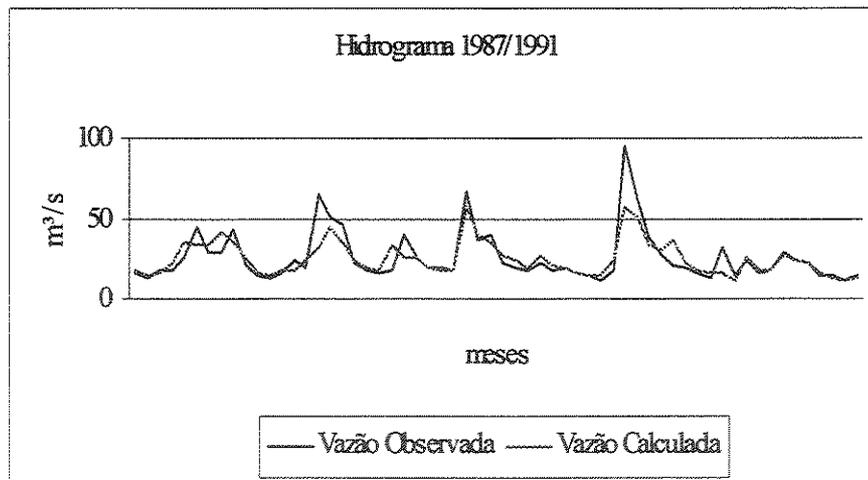
- Topologia (2,3,1)

**Gráfico 5.11 – Bacia do Rio Itapetininga – Caso3 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (2,3,1)- – Período 1987 a 1991**



- Topologia (2,7,1)

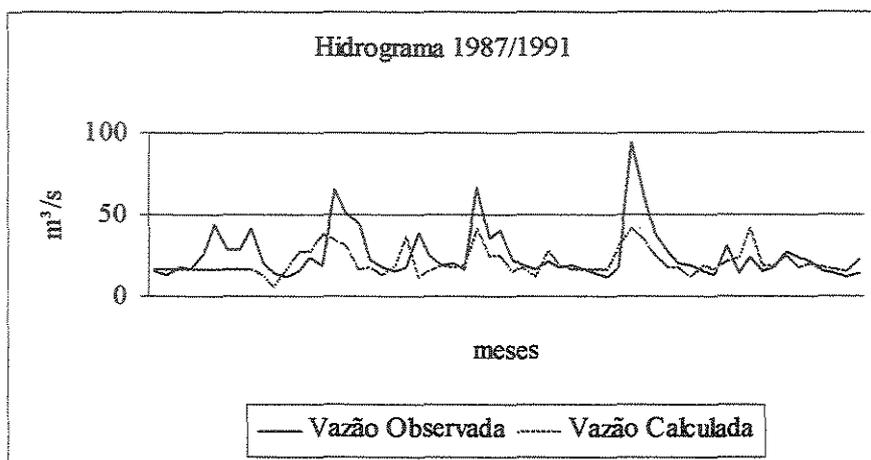
**Gráfico 5.12 – Bacia do Rio Itapetininga – Caso3 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (2,7,1)- – Período 1987 a 1991**



**D. Caso 4**

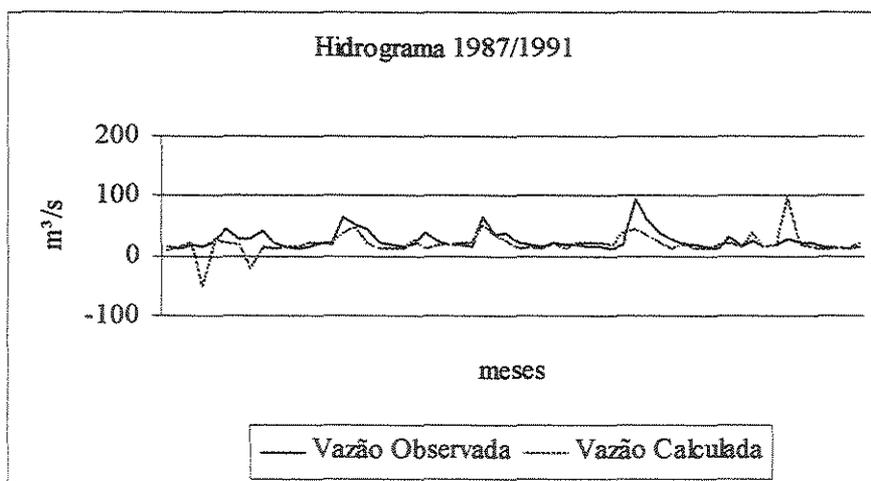
- Topologia (2,3,1)

**Gráfico 5.13 – Bacia do Rio Itapetininga – Caso4 - Hidrograma das Vazões Médias Mensais (m<sup>3</sup>/s) – Validação Topologia (2,3,1)- – Período 1987 a 1991**



- Topologia (2,7,1)

**Gráfico 5.14 – Bacia do Rio Itapetininga – Caso4 - Hidrograma das Vazões Médias Mensais (m<sup>3</sup>/s) – Validação Topologia (2,7,1)- – Período 1987 a 1991**



5.5.2.2 Bacia do Rio das Almas

Tabela 5.6 – Bacia do Rio das Almas – Calibração e Validação: Erro Quadrático

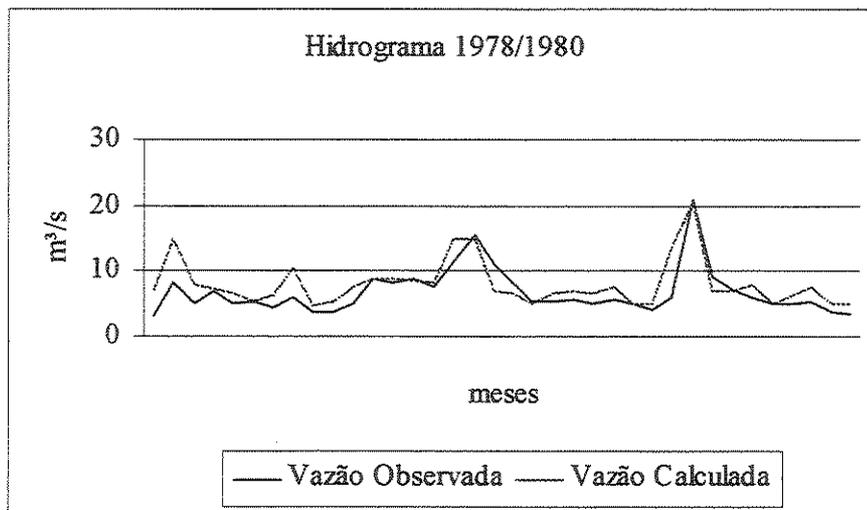
Bacia	Rio das Almas							
	Calibração				Teste			
Topologia	(1,3,1)	(1,7,1)	(2,3,1)	(2,7,1)	(1,3,1)	(1,7,1)	(2,3,1)	(2,7,1)
Caso1	2,9973	2,9268			1,2611	2,4151		
Caso2	2,1791	1,8499			1,6953	1,0124		
Caso3			1,4874	0,8966			0,7935	0,7834
Caso4			2,0194	0,9478			1,2624	4,9090

As vazões calculadas para este caso têm seus resultados resumidos nas tabelas abaixo:

A. Caso 1

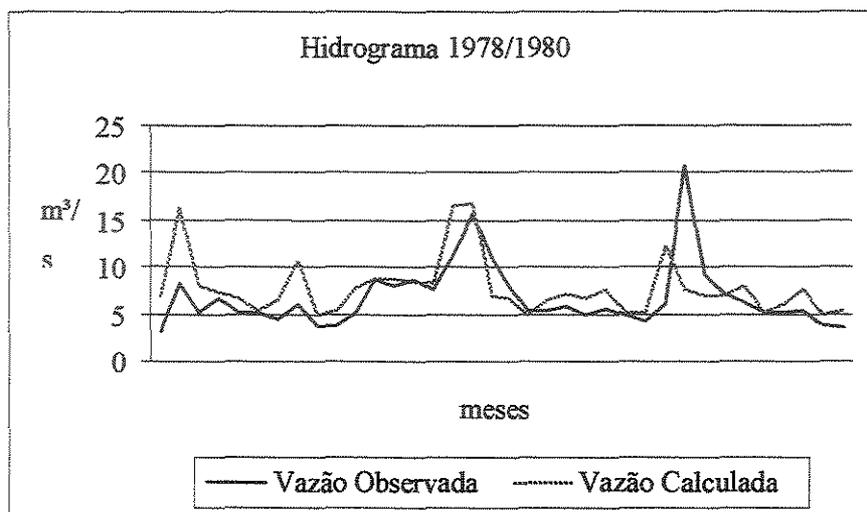
- Topologia (1,3,1)

Gráfico 5.15 – Bacia do Rio das Almas – Caso1 - Hidrograma das Vazões Médias Mensais – (m³/s) - Validação Topologia (1,3,1)- – Período 1978 a 1980



- Topologia (1,7,1)

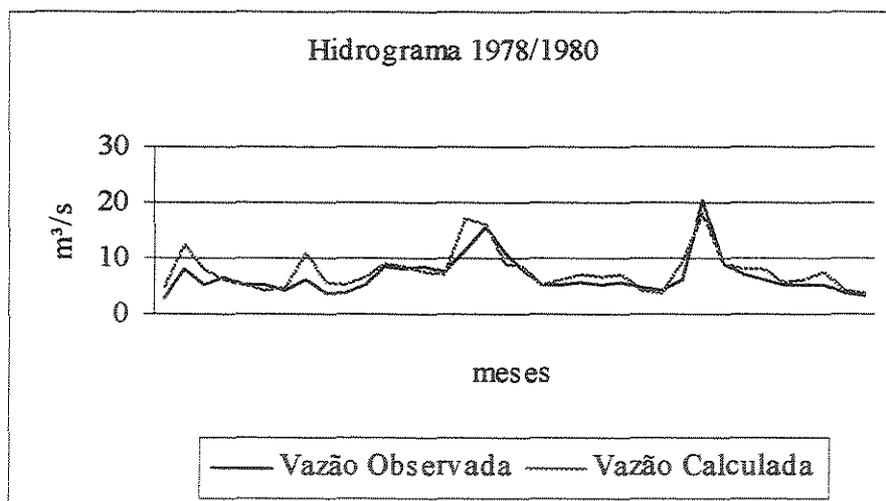
**Gráfico 5.16 – Bacia do Rio das Almas – Caso1 - Hidrograma das Vazões Médias Mensais – (m<sup>3</sup>/s) - Validação Topologia (1,7,1)- – Período 1978 a 1980**



**B. Caso 2**

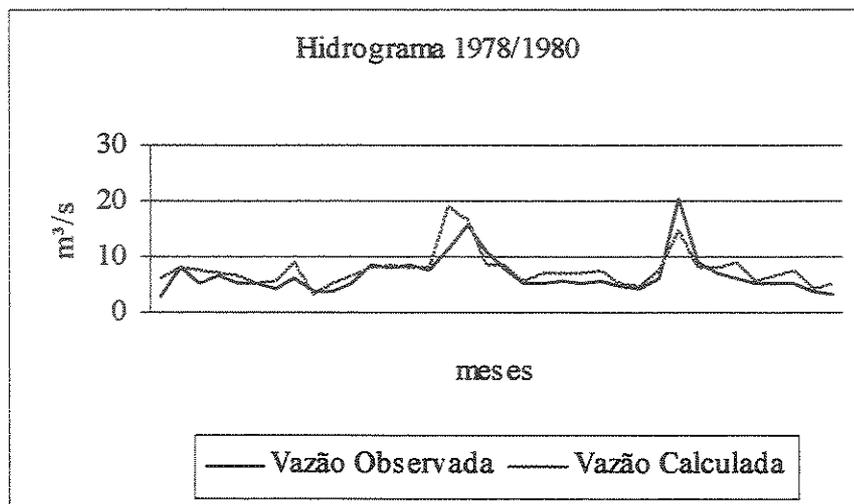
- Topologia (1,3,1)

**Gráfico 5.17 – Bacia do Rio das Almas – Caso2 - Hidrograma das Vazões Médias Mensais (m<sup>3</sup>/s) – Validação Topologia (1,3,1)- – Período 1978 a 1980**



- Topologia (1,7,1)

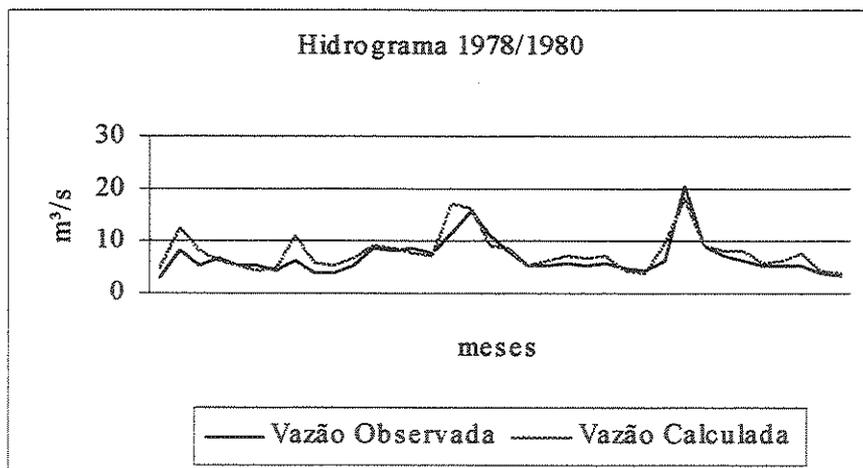
**Gráfico 5.18 – Bacia do Rio das Almas – Caso2 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (1,7,1)- – Período 1978 a 1980**



**C. Caso 3**

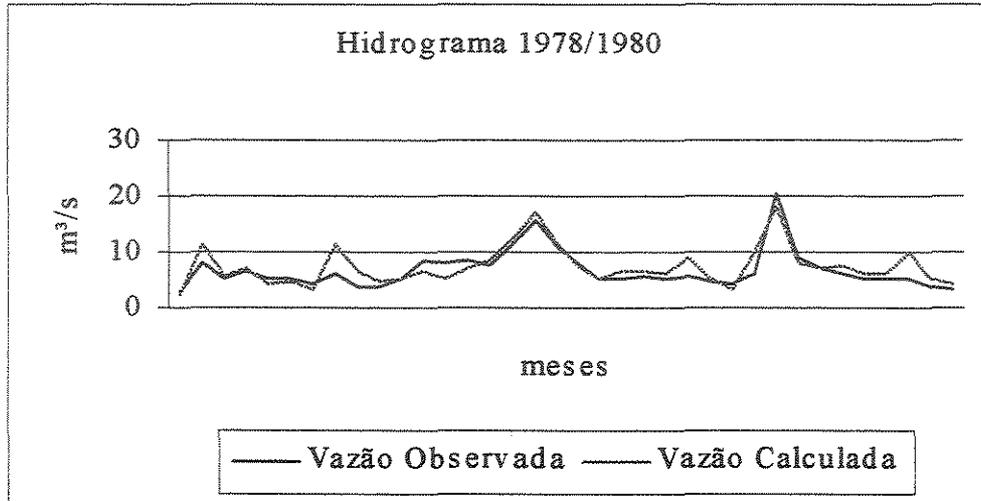
- Topologia (2,3,1)

**Gráfico 5.19 – Bacia do Rio das Almas – Caso3 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (2,3,1)- – Período 1978 a 1980**



- Topologia (2,7,1)

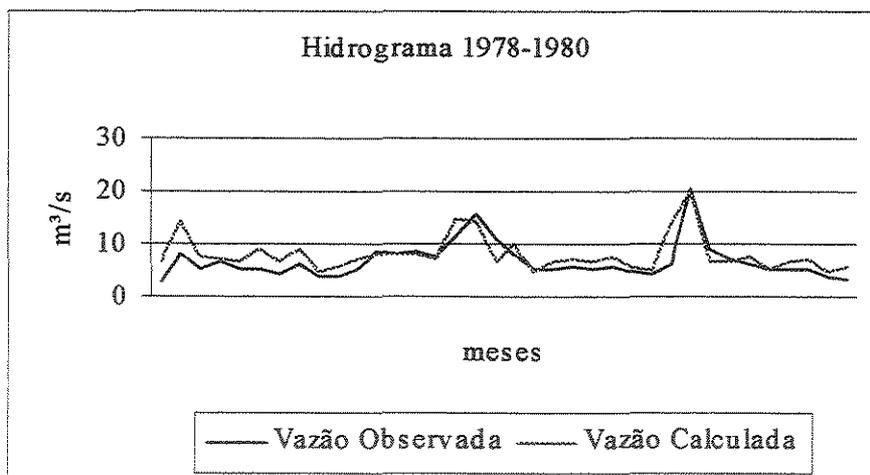
**Gráfico 5.20 – Bacia do Rio das Almas – Caso3 - Hidrograma das Vazões Médias Mensais (m<sup>3</sup>/s) – Validação Topologia (2,7,1)- – Período 1978 a 1980**



**D. Caso 4**

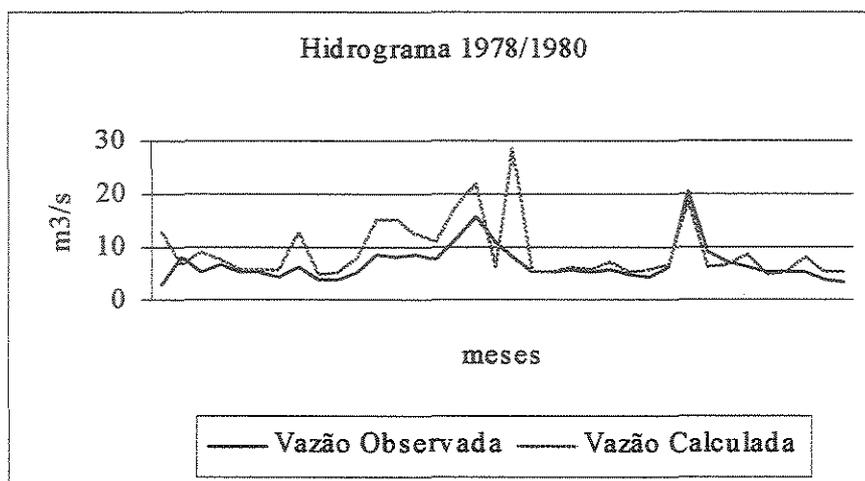
- Topologia (2,3,1)

**Gráfico 5.21 – Bacia do Rio das Almas – Caso4 - Hidrograma das Vazões Médias Mensais (m<sup>3</sup>/s) – Validação Topologia (2,3,1)- – Período 1978 a 1980**



- Topologia (2,7,1)

**Gráfico 5.22 – Bacia do Rio das Almas – Caso4 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (2,7,1)- – Período 1978 a 1980**



### 5.5.2.3 Bacia do Rio Guarapiranga

**Tabela 5.7 – Bacia do Rio Guarapiranga – Calibração e Validação: Erro Quadrático**

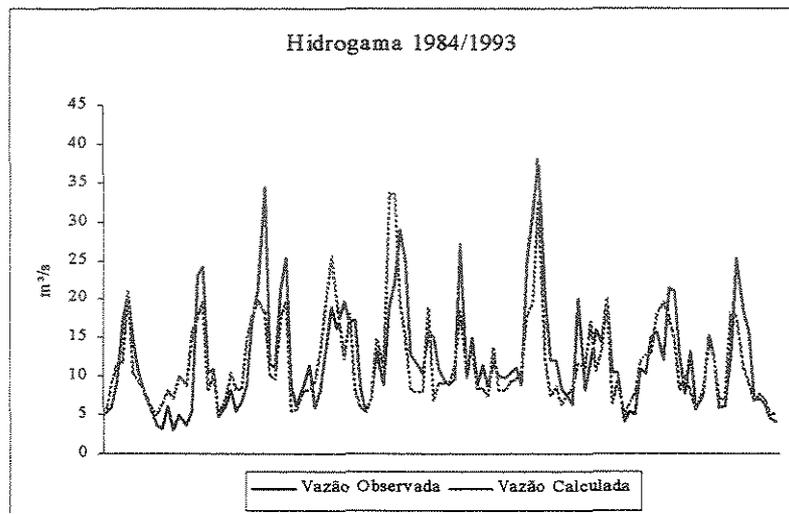
Bacia	Rio Guarapiranga							
	Calibração				Teste			
Topologia	(1,3,1)	(1,7,1)	(2,3,1)	(2,7,1)	(1,3,1)	(1,7,1)	(2,3,1)	(2,7,1)
Caso1	6,4061	6,4344			2,8385	2,7928		
Caso2	4,8317	4,7969			2,2811	2,3140		
Caso3			5,4930	5,4569			2,2390	2,3029

As vazões calculadas para este caso, têm seus resultados resumidos nas tabelas abaixo:

**A. Caso 1**

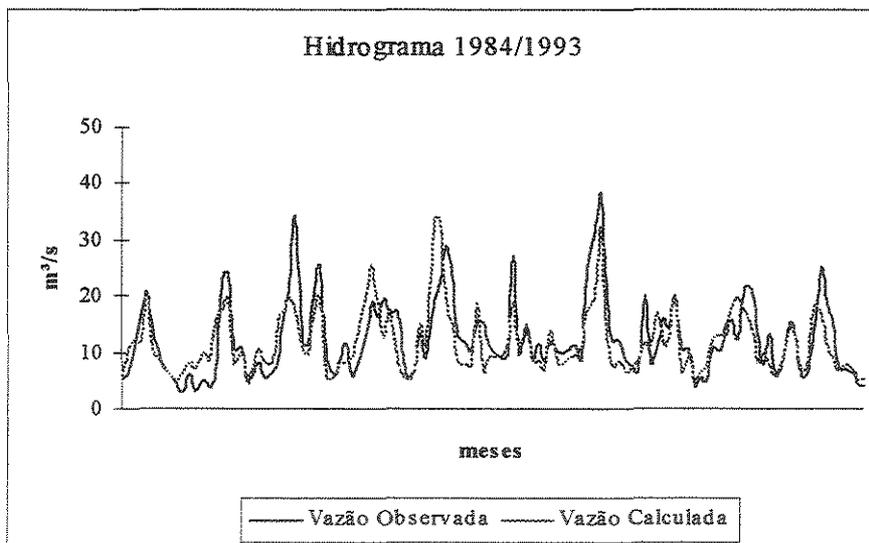
- Topologia (1,5,1)

**Gráfico 5.23 – Bacia do Rio Guarapiranga – Caso1 - Hidrograma das Vazões Médias Mensais (m<sup>3</sup>/s) – Validação Topologia (1,5,1)- – Período 1984 a 1993**



- Topologia (1,7,1)

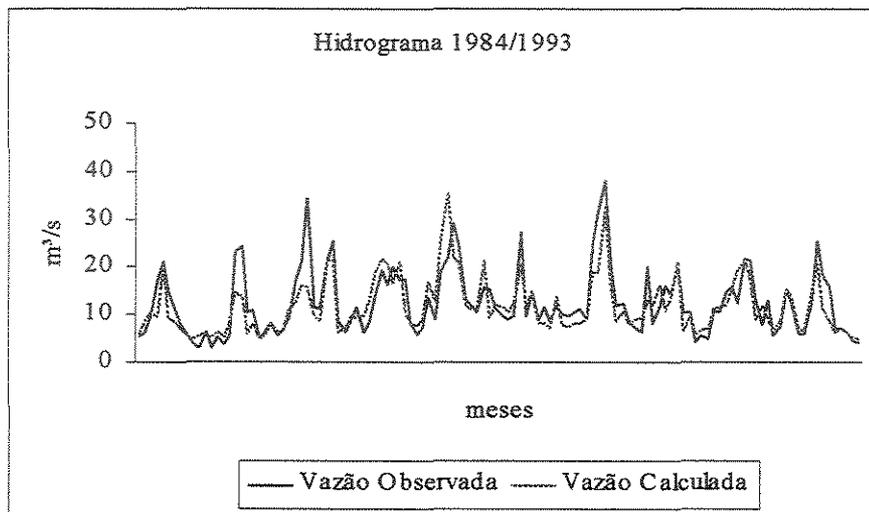
**Gráfico 5.24 – Bacia do Rio Guarapiranga – Caso1 - Hidrograma das Vazões Médias Mensais (m<sup>3</sup>/s) – Validação Topologia (1,7,1)- – Período 1984 a 1993**



**B. Caso 2**

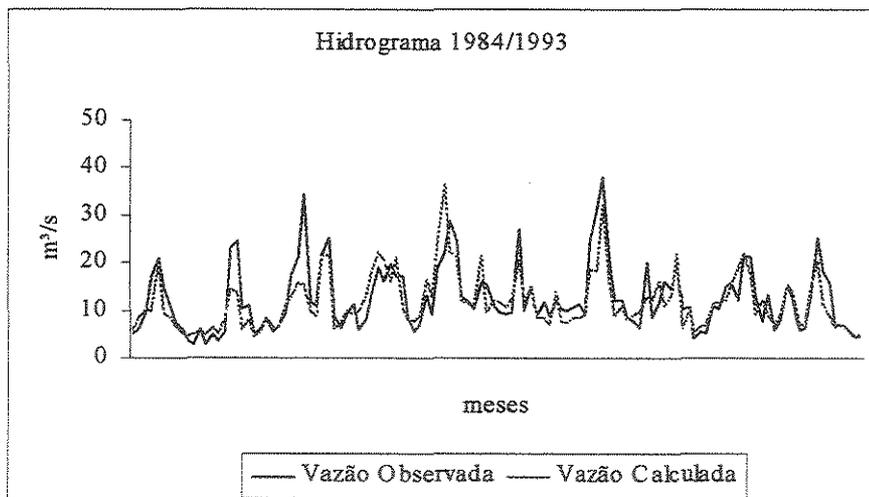
- Topologia (1,5,1)

**Gráfico 5.25 – Bacia do Rio Guarapiranga – Caso2 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (1,5,1)- – Período 1984 a 1993**



- Topologia (1,7,1)

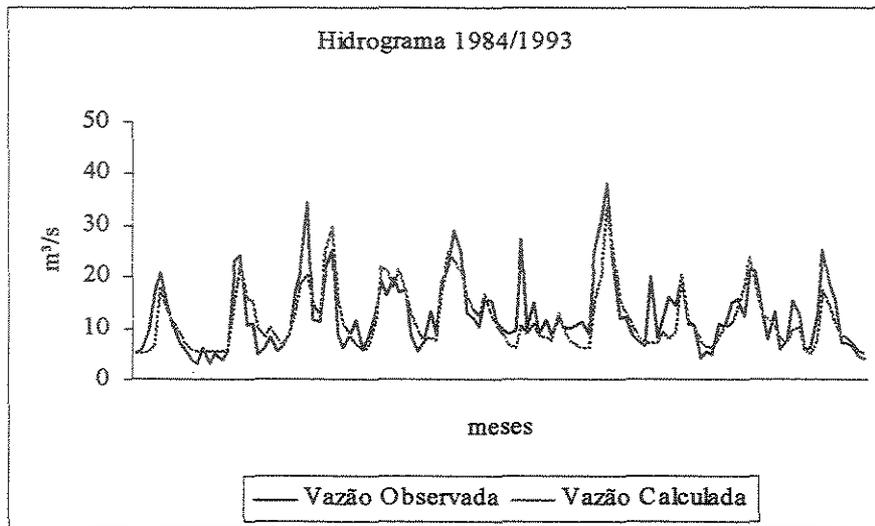
**Gráfico 5.26 – Bacia do Rio Guarapiranga – Caso2 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (1,7,1)- – Período 1984 a 1993**



**C. Caso 3**

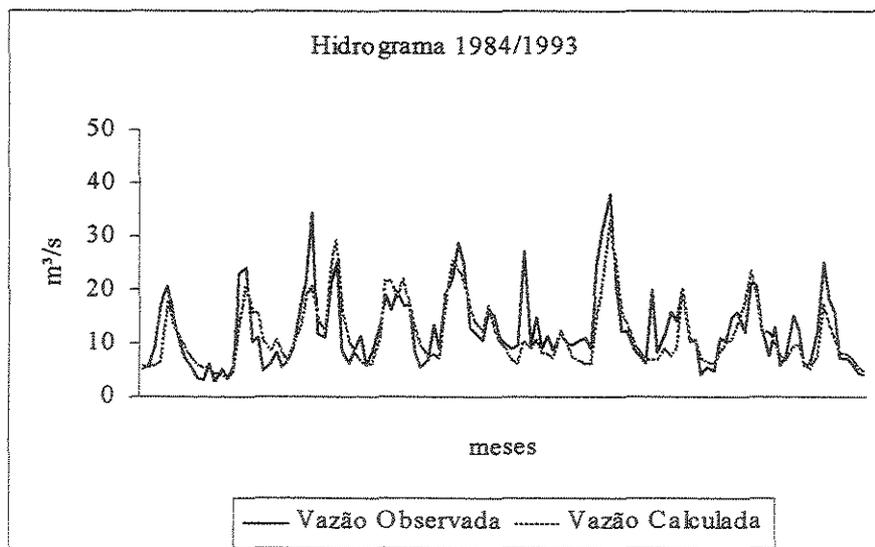
- Topologia (2,5,1)

**Gráfico 5.27 – Bacia do Rio Guarapiranga – Caso3 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (2,5,1)- – Período 1984 a 1993**



- Topologia (2,7,1)

**Gráfico 5.28 – Bacia do Rio Guarapiranga – Caso3 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (2,7,1)- – Período 1984 a 1993**



5.5.2.4 Bacia do Rio Guaporé

Tabela 5.8 – Bacia do Rio das Almas – Calibração e Validação: Erro Quadrático

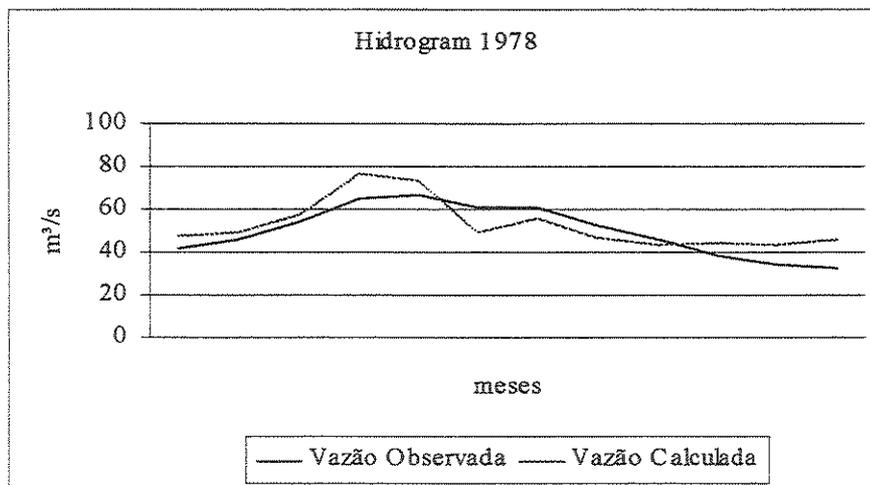
Bacia		Rio Guaporé							
Número de Iterações = 300									
Topologia	Calibração				Teste				
	(1,7,1)	(1,10,1)	(2,7,1)	(2,10,1)	(1,7,1)	(1,10,1)	(2,7,1)	(2,10,1)	
Caso1	2,2919	2,2963			0,2546	0,2412			
Caso2	0,8477	0,7231			0,2961	0,2913			
Caso3			0,2783	0,3013			0,1769	0,1755	

As vazões calculadas para este caso têm seus resultados resumidos nas tabelas abaixo:

A. Caso 1

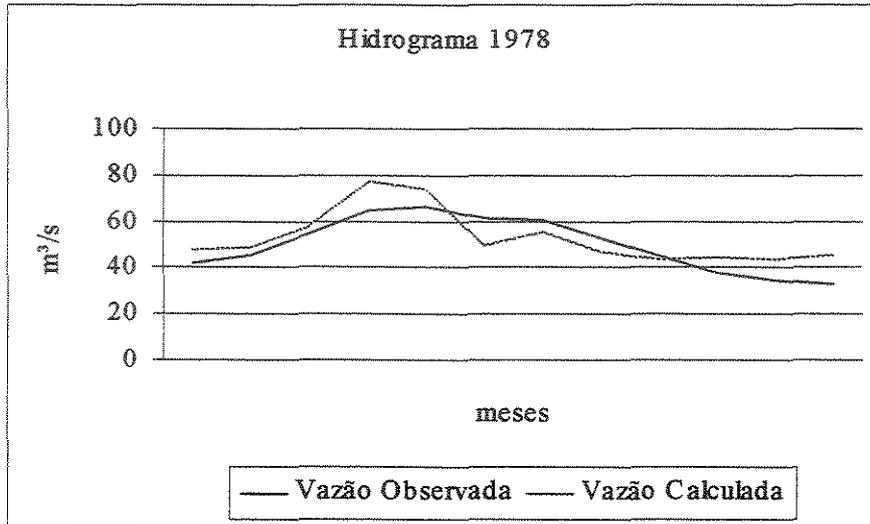
- Topologia (1,7,1)

Gráfico 5.29 – Bacia do Rio Guaporé – Caso1 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (1,7,1)- – Período 1977 a 1978



- Topologia (1,10,1)

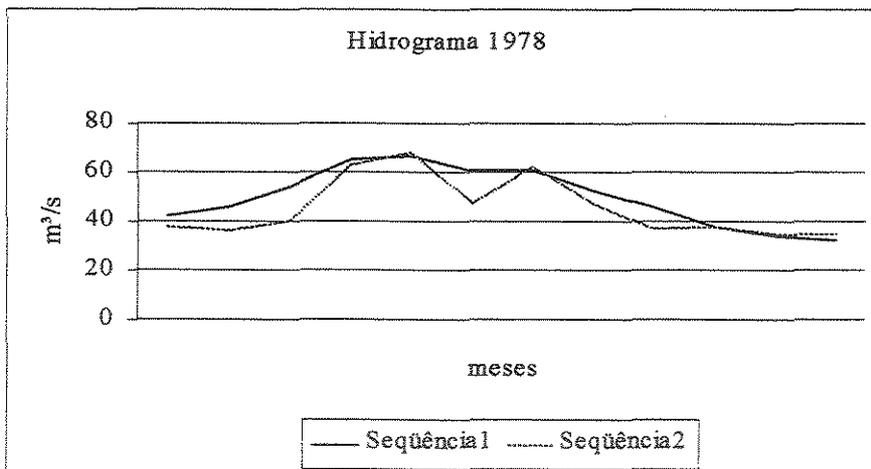
**Gráfico 5.30 – Bacia do Rio Guaporé – Caso1 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (1,10,1)- – Período 1977 a 1978**



**B. Caso 2**

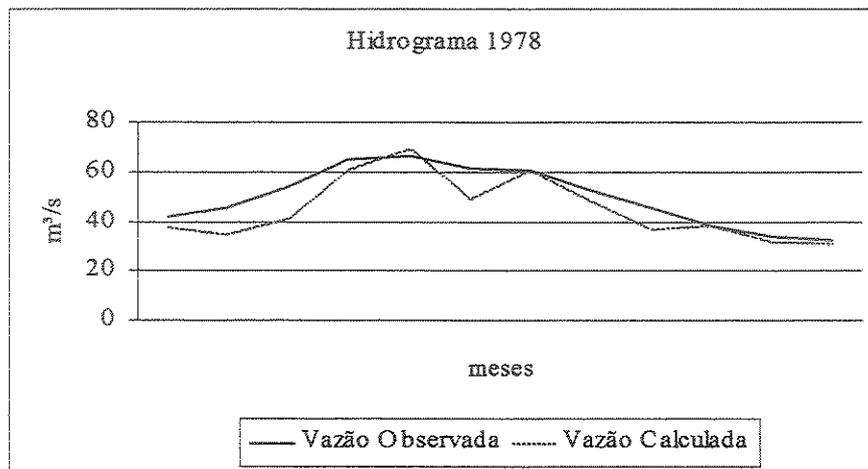
- Topologia (1,7,1)

**Gráfico 5.31 – Bacia do Rio Guaporé – Caso2 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (1,7,1)- – Período 1977 a 1978**



- Topologia (1,10,1)

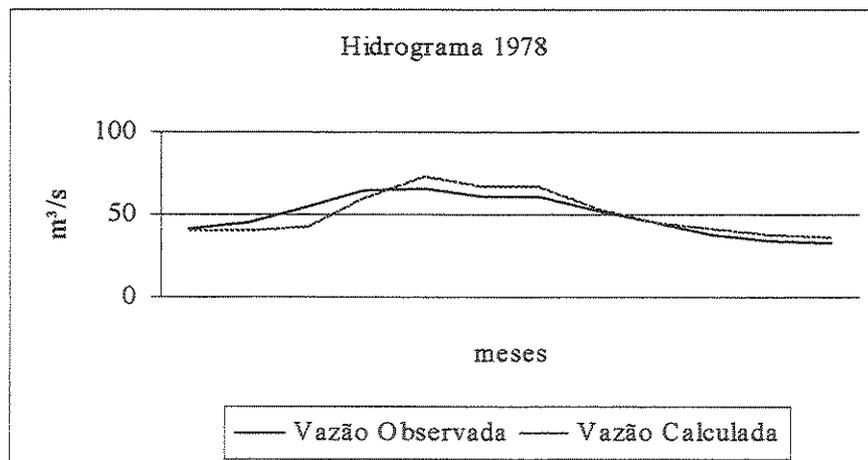
**Gráfico 5.32 – Bacia do Rio Guaporé – Caso2 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (1,10,1)- – Período 1977 a 1978**



**C. Caso 3**

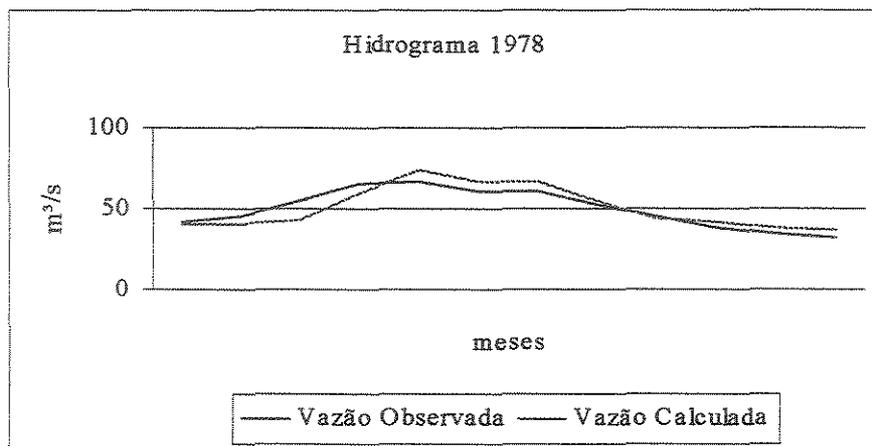
- Topologia (2,7,1)

**Gráfico 5.33 – Bacia do Rio Guaporé – Caso3 - Hidrograma das Vazões Médias Mensais (m³/s) – Validação Topologia (2,7,1)- – Período 1977 a 1978**



- Topologia (2,10,1)

**Gráfico 5.34 – Bacia do Rio Guaporé – Caso3 - Hidrograma das Vazões Médias Mensais (m<sup>3</sup>/s) – Validação Topologia (2,10,1)- – Período 1977 a 1978**



## 5.6 Análise dos Resultados

Os modelos foram submetidos inicialmente a um critério de escolha com base no melhor ajuste entre as séries observadas e calculadas segundo os critérios de simulação: SMAPm obtendo-se os melhores parâmetros do modelo com relação à aderência das séries e o RNA's com base na topologia da rede que apresentasse o menor erro quadrático.

No entanto o rigor na seleção destes modelos, ou melhor, nas alternativas criadas de simulação, estende-se a outras avaliações de caráter estatístico. Foram realizados ensaios tanto no processo de calibração como no processo de validação para as diversas alternativas, respectivamente.

Os resultados encontrados para estes estudos, na seqüência, serão identificados na forma de tabelas somente para o processo de validação, tendo como referência a bacia e relacionando cada modelo executado.

### **5.6.1 Resultados**

Inicialmente encontram-se tabelados os resultados para o modelo neural com seus respectivos casos de simulação de acordo a topologia selecionada e o modelo SMAPm conforme a quantidade de séries validadas, com referência a cada bacia hidrográfica. Neste conjunto estão os parâmetros numéricos estatísticos, médias mensais das vazões observadas e calculadas e seus respectivos desvios padrão; a correlação e a variância entre as séries: bacia do rio Itapetininga **Tabela 5.9**; bacia do rio das Almas – **Tabela 5.12**, bacia do rio Guarapiranga – **Tabela 5.15** e bacia do rio Guaporé – **Tabela 5.18**. O próximo bloco de resultados estatísticos – critérios AIC e BIC - visa conduzir a uma seleção baseada nos resultados da validação: bacia do rio Itapetininga **Tabela 5.10**; bacia do rio das Almas – **Tabela 5.13**; bacia do rio Guarapiranga – **Tabela 5.16** e bacia do rio Guaporé – **Tabela 5.19**.

Na seqüência das avaliações estatísticas os resultados calculados para RMSE, %VE, %MF e CORR, também validados para a série, estão assim distribuídos: bacia do rio Itapetininga **Tabela 5.11**; bacia do rio das Almas – **Tabela 5.14**, bacia do rio Guarapiranga – **Tabela 5.17** e bacia do rio Guaporé – **Tabela 5.20**. Todos estes parâmetros forma calculados pelo aplicativo Microsoft®Excel 97.

## 5.6.1.1 Bacia do Rio Itapetininga

Tabela 5.9 – Bacia do Rio Itapetininga – Validação RNA e SMAP: Vazão Média, Desvio Padrão, Correlação e Variância

	Vazão Média		Desvio Padrão		Correlação	Variância
	Observada	Calculada	Observada	Calculada		
<i>RNA</i>						
<b>Caso 1</b>						
Topologia (1,3,1)	25,61	24,16	15,88	11,16	0,73	188,99
Topologia (1,7,1)	25,61	22,60	15,88	10,43	0,70	181,29
<b>Caso 2</b>						
Topologia (1,3,1)	25,61	28,00	15,88	11,79	0,84	195,44
Topologia (1,7,1)	25,61	29,03	15,88	15,98	0,84	254,63
<b>Caso 3</b>						
Topologia (2,3,1)	25,61	24,72	15,88	10,86	0,82	183,75
Topologia (2,7,1)	25,61	24,63	15,88	10,79	0,85	183,04
<b>Caso 4</b>						
Topologia (2,3,1)	25,61	20,96	15,88	7,91	0,55	161,56
Topologia (2,7,1)	25,61	20,32	15,88	17,36	0,40	281,50
<i>SMAP</i>						
SMAPv1	27,48	27,33	15,22	13,07	0,711	198,29
SMAPv2	24,92	23,54	17,13	14,22	0,929	244,80

Tabela 5.10 – Bacia do Rio Itapetininga - Valores Calculados dos Critérios AIC e BIC para as Topologias de RNA e o Modelo SMAP

Modelo	AIC	BIC
<i>RNA</i>		
<b>Caso 1</b>		
RNA (1,3,1)	150,6	149,0*
RNA (1,7,1)	165,5	162,2
<b>Caso 2</b>		
RNA (1,3,1)	151,5	149,9*
RNA (1,7,1)	174,4	171,0
<b>Caso 3</b>		
RNA (2,3,1)	155,9	153,6*
RNA (2,7,1)	179,8	174,9
<b>Caso 4</b>		
RNA (2,3,1)	88,7	150,3*
RNA (2,7,1)	92,0	186,1
<i>SMAP</i>		
SMAPv1	88,7	87,4*
SMAPv2	92,0	90,7

(\*) Valores com menor taxa

**Tabela 5.11 – Bacia do Rio Itapetininga - Comparação Estatística entre os Resultados dos Modelos de RNA e SMAP**

N°	Modelo	N. de Parâm.	RMSE		%VE		%MP		CORR	
			Calibr.	Valid.	Calibr.	Valid.	Calibr.	Valid.	Calibr.	Valid.
<b>RNA</b>										
<b>Caso 1</b>										
1	RNA (1,3,1)	7	6,50	11,12	-0,008	11,32	-4,56	10,52	0,73	0,84
2	RNA (1,7,1)	15	11,10	11,61	0,000	11,74	-4,42	13,18	0,70	0,70
<b>Caso 2</b>										
3	RNA (1,3,1)	7	6,44	8,98	0,005	-9,34	6,65	6,88	0,89	0,84
4	RNA (1,7,1)	15	6,42	9,52	-0,005	-13,37	6,30	-6,31	0,89	0,84
<b>Caso 3</b>										
5	RNA (2,3,1)	10	5,61	9,38	0,006	3,46	3,16	1,14	0,91	0,82
6	RNA (2,7,1)	22	5,12	8,75	0,007	3,83	0,39	21,34	0,92	0,85
<b>Caso 4</b>										
7	RNA (2,3,1)	10	10,70	14,02	0,002	18,15	-5,57	32,21	0,66	0,55
8	RNA (2,7,1)	22	9,07	18,91	-0,114	20,64	1,13	-15,44	0,78	0,40
<b>SMAP</b>										
9	SMAP1	3	8,94	10,93	2,19	0,53	-12,86	6,36	0,79	0,71
10	SMAP2	3	5,70	6,72	5,02	5,56	-5,32	7,65	0,74	0,93
11	SMAP3	3	8,94	-	-0,70	-	2,81	-	0,79	-
12	SMAP4	3	8,53	-	8,12	-	19,74	-	0,89	-

## 5.6.1.2 Rio da Bacia do Rio das Almas

Tabela 5.12 – Bacia do Rio das Almas – Validação RNA e SMAP: Vazão Média, Desvio Padrão, Correlação e Variância

	Vazão Média		Desvio Padrão		Correlação	Variância
	Observada	Calculada	Observada	Calculada		
<b>RNA</b>						
<b>Caso 1</b>						
Topologia (1,3,1)	6,79	8,01	3,48	3,50	0,81	12,40
Topologia (1,7,1)	6,79	7,79	3,48	3,12	0,51	11,03
<b>Caso 2</b>						
Topologia (1,3,1)	6,79	7,73	3,48	3,49	0,88	12,21
Topologia (1,7,1)	6,79	7,74	3,48	3,18	0,82	11,18
<b>Caso 3</b>						
Topologia (2,3,1)	6,79	7,73	3,48	3,49	0,88	12,20
Topologia (2,7,1)	6,79	7,49	3,48	3,49	0,86	12,10
<b>Caso 4</b>						
Topologia (2,3,1)	6,79	8,08	3,48	3,31	0,81	11,79
Topologia (2,7,1)	6,79	9,08	3,48	5,54	0,62	22,43
<b>SMAP</b>						
SMAPv1	6,79	7,17	3,48	4,01	0,92	13,93

Tabela 5.13 – Bacia do Rio das Almas - Valores Calculados dos Critérios AIC e BIC para as Topologias de RNA e o Modelos SMAP

Modelo	AIC	BIC
<b>RNA</b>		
<b>Caso 1</b>		
RNA (1,3,1)	53,4	50,3 *
RNA (1,7,1)	67,5	60,9
<b>Caso 2</b>		
RNA (1,3,1)	53,1	50,0 *
RNA (1,7,1)	67,7	61,1
<b>Caso 3</b>		
RNA (2,3,1)	59,1	54,7 *
RNA (2,7,1)	83,0	73,2
<b>Caso 4</b>		
RNA (2,3,1)	58,6	54,1 *
RNA (2,7,1)	92,6	82,9
<b>SMAP</b>		
SMAPv1	47,2	45,9 *

(\*) Valores com menor taxa

**Tabela 5.14 – Bacia do Rio das Almas - Comparação Estatística entre os Resultados dos Modelos de RNA e SMAP**

N°	Modelo	N. de Parâms	RMSE		%VE		%MF		CORR	
			Calibr.	Valid.	Calibr.	Valid.	Calibr.	Valid.	Calibr.	Valid.
<b>RNA</b>										
<b>Caso 1</b>										
1	RNA (1,3,1)	11	2,68	2,46	0,055	-17,94	-0,82	-21,36	0,72	0,81
2	RNA (1,7,1)	15	2,64	3,40	-0,0004	-14,69	5,35	-18,28	0,73	0,51
<b>Caso 2</b>										
3	RNA (1,3,1)	11	1,89	1,94	0,001	-13,81	17,84	-12,08	0,87	0,88
4	RNA (1,7,1)	15	2,10	2,20	0,065	-14,00	6,44	0,03	0,84	0,82
<b>Caso 3</b>										
5	RNA (2,3,1)	16	1,89	1,95	-0,016	-13,84	7,93	-11,96	0,87	0,88
6	RNA (2,7,1)	22	1,46	1,94	-0,003	-10,29	0,94	-9,93	0,93	0,86
<b>Caso 4</b>										
7	RNA (2,3,1)	16	2,20	2,46	0,012	-18,92	-2,35	-18,12	0,82	0,81
8	RNA (2,7,1)	22	1,50	4,84	0,0002	-33,73	1,46	-48,22	0,92	0,62
<b>SMAP</b>										
9	SMAP1	3	2,59	1,63	10,15	-5,52	9,24	-19,91	0,78	0,92
10	SMAP2	3	3,24	-	17,99	-	17,34	-	0,72	-
11	SMAP3	3	3,16	-	-27,91	-	-39,72	-	0,70	-

### 5.6.1.3 Rio da Bacia do Rio Guarapiranga

**Tabela 5.15 – Bacia do Rio Guarapiranga – Validação RNA e SMAP: Vazão Média, Desvio Padrão, Correlação e Variância**

	Vazão Média		Desvio Padrão		Correlação	Variância
	Observada	Calculada	Observada	Calculada		
<b>RNA</b>						
<b>Caso 1</b>						
Topologia (1,3,1)	12,48	11,75	6,97	6,97	0,75	41,18
Topologia (1,7,1)	12,48	11,72	6,97	12,77	0,75	41,09
<b>Caso 2</b>						
Topologia (1,3,1)	12,48	11,73	6,97	5,80	0,80	41,08
Topologia (1,7,1)	12,48	11,74	6,97	5,85	0,80	41,38
<b>Caso 3</b>						
Topologia (2,3,1)	12,48	11,64	6,97	5,87	0,81	41,49
Topologia (2,7,1)	12,48	11,61	6,97	5,94	0,81	41,94
<b>SMAP</b>						
SMAPv1	12,00	10,04	7,45	5,68	0,66	44,60
SMAPv2	13,31	11,32	6,91	5,09	0,79	37,60

**Tabela 5.16 – Bacia do Rio Guarapiranga - Valores Calculados dos Critérios AIC e BIC para as Topologias de RNA e o Modelos SMAP**

<i>Modelo</i>	<i>AIC</i>	<i>BIC</i>
<i>RNA</i>		
<b>Caso 1</b>		
RNA (1,3,1)	215,8	210,9
RNA (1,7,1)	223,6	217,0
<b>Caso 2</b>		
RNA (1,3,1)	215,6	210,8
RNA (1,7,1)	224,0	217,4
<b>Caso 3</b>		
RNA (2,3,1)	226,2	219,1
RNA (2,7,1)	238,7	229,0
<i>SMAP</i>		
SMAPv1	164,3	163,4
SMAPv2	157,2	156,3

(\*) Valores com menor taxa

**Tabela 5.17 – Bacia do Rio Guarapiranga - Comparação Estatística entre os Resultados dos Modelos de RNA e SMAP**

<i>No</i>	<i>Modelo</i>	<i>N. de Parâm.</i>	<i>RMSE</i>		<i>%VE</i>		<i>%MF</i>		<i>CORR</i>	
			<i>Calibr.</i>	<i>Valid.</i>	<i>Calibr.</i>	<i>Valid.</i>	<i>Calibr.</i>	<i>Valid.</i>	<i>Calibr.</i>	<i>Valid.</i>
<i>RNA</i>										
<b>Caso 1</b>										
1	RNA (1,5,1)	11	4,06	4,68	0,327	5,86	4,27	9,74	0,75	0,75
2	RNA (1,7,1)	15	4,06	4,70	0,004	6,16	7,12	7,58	0,75	0,75
<b>Caso 2</b>										
3	RNA (1,5,1)	11	3,48	4,21	-0,055	6,04	20,26	10,39	0,84	0,80
4	RNA (1,7,1)	15	3,51	4,24	0,001	5,94	6,53	10,16	0,84	0,80
<b>Caso 3</b>										
5	RNA (2,5,1)	16	3,76	4,21	-0,004	6,04	9,32	10,39	0,78	0,81
6	RNA (2,7,1)	22	3,75	4,23	-0,011	7,02	9,22	13,20	0,78	0,81
<i>SMAP</i>										
7	SMAPv1	3	3,94	5,99	13,38	16,34	26,95	25,61	0,81	0,66
8	SMAPv2	3	3,60	4,67	15,73	14,96	23,76	17,73	0,89	0,79

### 5.6.1.4 Bacia do Rio Guaporé

**Tabela 5.18 – Bacia do Rio Guaporé – Validação RNA e SMAP: Vazão Média, Desvio Padrão, Correlação e Variância**

	<i>Vazão Média</i>		<i>Desvio Padrão</i>		<i>Correlação</i>	<i>Variância</i>
	<i>Observada</i>	<i>Calculada</i>	<i>Observada</i>	<i>Calculada</i>		
<i>RNA</i>						
<b>Caso 1</b>						
Topologia (1,7,1)	49,87	52,72	11,92	12,24	0,79	131,81
Topologia (1,10,1)	49,87	51,35	11,92	11,59	0,79	134,48
<b>Caso 2</b>						
Topologia (1,7,1)	49,87	49,87	11,92	12,24	0,88	140,58
Topologia (1,10,1)	49,87	44,84	11,92	12,71	0,91	151,82
<b>Caso 3</b>						
Topologia (2,7,1)	49,87	50,39	11,92	12,94	0,90	148,09
Topologia (2,10,1)	49,87	50,58	11,92	12,98	0,90	148,62
<i>SMAP</i>						
SMAPv1	51,24	45,37	11,6	12,45	0,83	150,44

**Tabela 5.19 – Bacia do Rio Guaporé - Valores Calculados dos Critérios AIC e BIC para as Topologias de RNA e o Modelos SMAP**

<i>Modelo</i>	<i>AIC</i>	<i>BIC</i>
<i>RNA</i>		
<b>Caso 1</b>		
RNA (1,7,1)	56,1	42,3 *
RNA (1,10,1)	68,1	48,8
<b>Caso 2</b>		
RNA (1,7,1)	57,4	43,6 *
RNA (1,10,1)	69,5	50,2
<b>Caso 3</b>		
RNA (2,7,1)	71,8	51,6 *
RNA (2,10,1)	89,9	61,3
<i>SMAP</i>		
SMAPv1	58,3	56,4 *

(\*) Valores com menor taxa

**Tabela 5.20 – Bacia do Rio Guaporé - Comparação Estatística entre os Resultados dos Modelos de RNA e SMAP**

No	Modelo	N. de Parâm.	RMSE		%VE		%MF		CORR	
			Calibr.	Valid.	Calibr.	Valid.	Calibr.	Valid.	Calibr.	Valid.
<i>RNA</i>										
<i>Caso 1</i>										
1	RNA (1,7,1)	15	12,50	7,80	-1,91	-5,73	7,76	-15,16	0,48	0,79
2	RNA (1,10,1)	21	12,54	7,95	-1,15	-5,95	3,46	-14,55	0,48	0,79
<i>Caso 2</i>										
3	RNA (1,7,1)	15	8,44	7,13	-1,88	8,60	-3,18	-2,69	0,82	0,88
4	RNA (1,10,1)	21	8,25	7,07	-1,90	10,07	-8,77	-4,44	0,83	0,91
<i>Caso 3</i>										
5	RNA (2,7,1)	22	8,54	5,51	-1,88	-1,05	-5,31	-9,97	0,84	0,90
6	RNA (2,10,1)	31	0,05	5,49	-2,14	-1,43	-5,20	-10,94	0,83	0,90
<i>SMAP</i>										
7	SMAPv1	3	6,11	9,13	-2,52	-11,46	7,76	0,45	0,94	0,83

### 5.6.2 Avaliação Estatística dos Resultados

Tendo como elementos de análise os parâmetros numéricos estatísticos (média aritmética, o desvio padrão, a correlação linear e a variância) registrados nas Tabelas 5.9; 5.12; 5.15 e 5.18 e os critérios de informações quanto à parcimônia do modelo (AIC e BIC)<sup>3</sup> nas Tabelas 5.10; 5.13; 5.16 e 5.19 os resultados encontrados no processo de simulação das respectivas bacias, considerando cada configuração dos modelos RNA's e SMAPm, serão analisados à luz desses elementos estatísticos.

A seleção das configurações dos modelos passíveis de otimalidade corresponde àquele com melhor valor dos parâmetros estatísticos que medem a variabilidade da variável – desvio padrão e variância e ao melhor valor de AIC e de BIC. Nota-se que neste tipo de julgamento, dependendo da finalidade de aplicação<sup>4</sup> do modelo a tomada de decisão sobre a escolha da melhor

<sup>3</sup> O valor mínimo foi atendido para os cenários marcados por um asterisco (\*).

<sup>4</sup> Construção de um reservatório de regularização de vazões: parâmetro numérico para se medir a variabilidade.

estrutura de modelo, com base nos parâmetros estatísticos e os critérios de parcimônia, sugere-se que seja submetida a métodos multicriteriais de ajuda a decisão (*multiple criteria decision aid*–MCDA), baseados nos riscos pertinentes a cada caso de estudo (OSSENBRUGGEN,1994; VINCKE, GASSNER E ROY, 1992). Neste estudo, não abordaremos este procedimento.

Analisando, segundo as medidas estatísticas e a parcimônia, os candidatos referentes a cada bacia são:

- **Bacia do Rio Itapetininga:** A série apresentou pequenos desvios e variância em relação à média, com boa correlação entre as vazões. Porém as topologias (2,3,1) e (2,7,1) do Caso4, foram as que apresentaram pior correlação. Quanto à parcimônia, o Caso1 - RNA(1,3,1); Caso2 - RNA(1,3,1); Caso3 - RNA(2,3,1); Caso4, - RNA(2,3,1) e finalmente SMAPm - validação2 (SMAPv1), foram os que obtiveram melhor resultados.
- **Bacia do Rio das Almas:** No procedimento de validação os valores dos parâmetros estatísticos foram os melhores dos ensaios do estudo de caso, observando que a correlação registrou valor acima de 0,8, com exceção do da topologia (1,3,1)do Caso 1 e (2,7,1) do Caso 4. Com relação a avaliação da parcimônia dos modelos, o Caso1 - RNA(1,3,1); Caso2 - RNA(1,3,1); Caso3 - RNA(2,3,1); Caso4, - RNA(2,3,1) e finalmente SMAPm - validação1(SMAPv1) apresentaram menores resultados.
- **Bacia do Rio Guarapiranga:** A variabilidade das séries hidrológicas não se apresentou acentuada; apenas a situação simulada SMAPv1 indicou baixa correlação. Foram selecionados Caso1 - RNA(1,7,1); Caso2 - RNA(1,7,1); Caso3 - RNA(2,7,1) e finalmente SMAPm – validação2 (SMAPv2) , por terem os valores dos critérios AIC e BIC menores.
- **Bacia do Rio Guaporé:** Os elementos estatísticos considerados nesta avaliação registram que a simulação apresentou uma boa proximidade entre os valores e quanto à parcimônia, para o modelo RNA's, as topologias com sete neurônios na camada intermediária, para todos os casos, foram as selecionadas e, SMAPv1.

De maneira a avaliar o desempenho das duas concepções diferentes de modelos (RNA's e SMAPm), foram aplicados métodos estatísticos de análise dos resíduos para os períodos de calibração e validação, sendo os resultados obtidos apresentados nas **Tabela 5.11**, **Tabela 5.14**, **Tabela 5.17** e **Tabela 5.20**.

Para cada bacia simulada, em relação às medidas estatísticas RMSE, %MF, %VE e CORR, a avaliação é a seguinte:

- **Bacia do Rio Itapetininga:** modelo de RNA(2,7,1) – Caso3, seguido pelo RNA(1,7,1) – Caso2, tendem a ter melhores valores na fase da calibração do que na fase de validação, em relação aos demais. A topologia RNA(2,7,1) do Caso3 mostra-se também melhor na calibração que o SMAP. Em geral, o modelo de redes RNA tem melhor desempenho nesta medida estatística (RMSE); os resultados da medida estatística %VE denotam que a maioria das estruturas dos modelos validados estão superestimadas (valores positivos acima de zero indicam superestimação) e nas séries calibradas, com erros percentuais em volume aproximadamente iguais a zero, evidencia-se superioridade do modelo de redes sobre o SMAPm. Durante a calibração a medida estatística %MF, (corresponde a um erro no escoamento máximo (pico) dos registros de dados) indica que o modelo SMAPm apresenta uma boa representação da vazão de pico na calibração 3. Enquanto que nos demais modelos esta representação é bastante satisfatória, excetuando-se o Caso4. Com relação à última medida de comparação estatística selecionada entre os modelos, os coeficientes de correlação entre valores observados e calculados (CORR) indicam que os calibrados movem-se muito mais próximos do que os dados validados nos modelos de RNA. É pertinente observar que, nos caso de RNA – Caso1 e Caso4, a topologia RNA(1,5,1) – Caso1, foi visivelmente superior nas avaliações estatísticas do que a do outro caso. A vantagem do modelo de redes (RNA) sobre o SMAP se revela em três das quatro estatísticas durante as 12 simulações estudadas para a fase de calibração e, no processo de validação, ocorre o contrário. Com base na avaliação dessas estatísticas merece destaque, pelos melhores resultados, a topologia RNA(2,7,1) do Caso3 e SMAP2.

- **Bacia do Rio das Almas:** Na solução de RMSE, no geral, apresentou valores bem baixo, o que indica uma ótima variação residual, principalmente na calibração dos casos de RNA's. Particularmente, a topologia RNA(2,7,1) apresentou ótimo resultado. O erro percentual de volume avaliado (%VE) denotou que nos caso relativos à calibração do RNA's os resultados foram próximos a zero, apenas ocorrendo uma subestimação em todos os casos validados, também para o SMAPm. O erro entre as vazões de pico (%MF) foram bem pequenos para os casos de RNA's, exceto a sobrestimação na topologia de validação do Caso2 RNA(1,5,1) e a subestimação na validação das topologia do Caso1 RNA(1,5,1) e Caso4 RNA(2,7,1). Excelente correlação linear é associada aos dados dos modelos RNA(2,7,1) Caso3 - calibração - e validação do SMAP1. Na avaliação geral desse estudo estatístico verifica-se que o modelo RNA's é superior ao SMAPm na calibração dos dados, porém a situação se inverte na validação do modelo. As configurações que se destacaram no conjunto das medias estatísticas foram a topologia RNA(2,7,1) do Caso3 e SMAP1.
- **Bacia do Rio Guarapiranga:** O erro padrão de estimativa (RMSE) atingiu seu valor ótimo para os casos calibrados do modelo RNA's, não desconsiderando os demais resultados dos outros casos simulados. Quanto ao erro percentual da vazão máxima (%MF) permanecem os melhores resultados para os casos calibrados no modelo RNA's, destacando-se a topologia RNA(1,7,1) Caso2. Durante a validação, o termo estatístico %MF apresenta valores mais baixos que na calibração, porém, em ambos os casos, com percentuais, em média, acima de 50%. A correlação linear é positiva e acima de 60%, em todos os casos, confirmando a associação dos grandes valores de um conjunto aos de outro. Comparando os resultados das medidas estatísticas avaliadas, o modelo RNA's obteve maior proveito do que o modelo SMAP. Dentre as 8 estatísticas em 6 o modelo RNA's obteve melhor resultados que o SMAPm (RNA's → 4 para calibração e 2 para validação, SMAPm → 2 para a calibração). As melhores configurações ficaram para a topologia RNA(1,7,1) do Caso3 e SMAPv2 .
- **Bacia do Rio Guaporé:** O valores da variância residual do erro padrão de estimativa oscilou entre 12,5% a 0,05% na simulação dos dois modelos, valor este considerado com ótima aproximação entre os valores. A subestimação ocorreu na grande maioria dos caso simulados—

calibrados e simulados em relação à medida estatística %VE, embora os melhores resultados sejam referentes à topologia RNA(2,7,1) do Caso3. O mesmo ocorreu com os resultados do erro %MF, principalmente para todos os casos do modelo de RNA's, embora a simulação SMAPv1 tenha registrado um valor próximo a zero. A melhor correlação foi destacada também para a simulação SMAPv1. Os melhores resultados, no geral, são encontrados na topologia RNA(2,10,1) do Caso3 e SMAPv1.

### 5.6.3 Síntese da Avaliação dos Resultados

A análise anterior permitiu comparar o desempenho dos modelos sob diferentes medidas estatísticas. Não obstante, cabe passar ao engenheiro que trabalha com a previsão de vazões como ferramenta para tomada de decisão, uma síntese comparativa sobre o desempenho dos modelos, especialmente na fase de validação. Para tanto, cabe considerar ainda um critério não tratado anteriormente, porém que faz parte da rotina do hidrólogo que trabalha com simulação de processos chuva-vazão: a inspeção visual. Mesmo que de uma forma não sistematizada rigidamente, os elementos seguintes serão observados na comparação dos hidrogramas (calculado x observado):

- a) Grau de aderência entre as vazões calculadas e as observadas (no geral);
- b) Reprodução das vazões de pico;
- c) Reprodução dos volumes (estimados visualmente pela área sob as curvas);
- d) Capacidade de as vazões calculadas pelo modelo “acompanharem” o hidrograma observado (mesmo que com atraso ou adiantamento, observar se o movimento de subida ou descida é homólogo no modelo e no hidrograma observado).

É óbvio que a avaliação de todos esses aspectos contém uma parcela de subjetividade, fruto da experiência do hidrólogo que faz a análise e também, fruto da prioridade do aspecto (ex. pico do hidrograma, volume sob a curva, etc.) que se julga mais relevante reproduzir. No entanto, em boa parte das simulações haverá consenso entre os hidrólogos analistas sobre o(s) melhor(es) resultados, principalmente se os critérios e o objetivo predominante forem pré-estabelecidos. A título ilustrativo e com base nos critérios listados previamente, apresenta-se na **Tabela 5.21** a hierarquia sobre o desempenho dos modelos (do melhor para o pior) sob inspeção visual, não sendo considerado nenhum critério como preponderante.

**Tabela 5.21 – Hierarquia de Melhores Resultados dos Modelos em Cada Bacia Segundo Inspeção Visual – Etapa de Validação**

<i>Bacia do Rio Itapetininga</i>	<i>Bacia do Rio Almas</i>	<i>Bacia do Rio Guarapiranga</i>	<i>Bacia do Rio Guaporé</i>
1) SMAP	1) SMAP	1) Caso 3 – RNA (2,5,1)	1) Caso 3 – RNA (2,7,1)
2) Caso 3 – RNA (2,7,1)	2) Caso 3 – RNA (2,7,1)	2) SMAP	2) SMAP
3) Caso 2 – RNA (1,7,1)	3) Caso 2 – RNA (1,3,1)	3) Caso 2 – RNA (1,5,1)	3) Caso 1 – RNA (1,7,1)
4) Caso 1 – RNA (1,3,1)	4) Caso 1 – RNA (1,3,1)	4) Caso 1 – RNA (1,5,1)	4) Caso 2 – RNA (1,7,1)
5) Caso 4 – RNA (2,3,1)	5) Caso 4 – RNA (2,3,1)		

Finalmente, considerando critérios estatísticos e a inspeção visual, são mostradas na **Tabela 5.22** as hierarquias dos dois modelos com melhores resultados na etapa de validação em cada bacia, a qual representa uma síntese dos resultados anteriores. Embora os critérios não sejam totalmente independentes entre si (ex. proximidade das vazões médias é similar a %VE), diversas considerações decorrem da análise comparativa feita nessa tabela, conforme comentado adiante.

Não há em qualquer das bacias estudadas um modelo em particular que se posicione na 1ª colocação da hierarquia para todos os critérios. Nem mesmo relaxando a exigência de 1ª colocação estrita para uma condição de “1ª ou 2ª colocação” não há modelo algum que consiga estar nesta condição (relaxada) para todos os critérios. Tal observação confirma estudos anteriores em que recomendações são feitas para nunca decidir sobre a escolha de um modelo baseando-se

---

em apenas um critério. Apenas à título ilustrativo, basta observar a **Figura 5.13** que apresenta o Caso 4 – RNA(2,3,1), o qual, segundo o critério de informação de Akaike teria sido o melhor modelo para a bacia do rio Itapetininga (ver **Tabela 5.22**). No entanto, a observação da **Figura 5.13**, comparada aos resultados do Caso 1, Caso 2 e Caso 3 (**Figuras 5.7, 5.9 e 5.11**, respectivamente) sistematizada conforme os critérios da inspeção visual (**Tabela 5.21**), revela que esse modelo figuraria na 4ª colocação.

**Tabela 5.22 – Duplas de Modelos com Melhores Desempenhos em cada Bacia, Segundo Avaliação de cada Critério (Período de Validação)**

<i>Bacia</i>	<i>Critério:</i> <i>Proximidade entre médias (Qcal x Qobs)</i>	<i>Proximidade Desvio-Padrão (Qcal x Qobs)</i>	<i>Correlação entre Qcal x Qobs</i>	<i>AIC (Akaike)</i>	<i>RMSE</i>	<i>% ME (desvios no pico)</i>	<i>% VE (desvios de volume calc. x obs.)</i>	<i>Inspeção Visual</i>
<b>Rio Itapetininga</b>	1) SMAPv2 2) Caso 3 - RNA(2,3,1)	1) Caso 2 - RNA(1,7,1) 2) SMAPv2	1) SMAPv2 2) Caso3 - RNA(2,7,1)	1) Caso 4 - RNA(2,3,1) 2) SMAPv2	1) SMAP2 2) Caso 3 - RNA(2,7,1)	1) Caso 3 - RNA(2,3,1) 2) Caso 2 - RNA(1,7,1)	1) Caso 3 - RNA(2,3,1) 2) SMAPv2	1) SMAPv2 2) Caso 3 - RNA(2,3,1)
<b>Rio das Almas</b>	1) SMAP 2) Caso 3 - RNA(2,7,1)	1) Caso 3 - RNA(2,7,1) 2) Caso 2 - RNA(1,3,1)	1) SMAP 2) Caso 3 - RNA(2,7,1)	1) SMAP 2) Caso 2 - RNA(1,3,1)	1) SMAP 2) Caso 3 - RNA(2,7,1)	1) Caso 2 - RNA(1,7,1) 2) Caso 3 - RNA(2,7,1)	1) SMAP 2) Caso 3 - RNA(2,7,1)	1) SMAP 2) Caso 3 - RNA(2,7,1)
<b>Rio Guarapiranga</b>	1) Caso 1 - RNA(1,3,1) 2) Caso 2 - RNA(1,7,1)	1) Caso 1 - RNA(1,3,1) 2) Caso 3 - RNA(1,7,1)	1) Caso 3 - RNA(2,5,1) 2) Caso 2 - RNA(1,7,1)	1) SMAP 2) Caso 2 - RNA(1,5,1)	1) Caso 2 - RNA(4,2,1) 2) Caso 3 - RNA(2,5,1)	1) Caso 1 - RNA(1,7,1) 2) Caso 2 - RNA(1,7,1)	1) Caso 1 - RNA(1,5,1) 2) Caso 2 - RNA(1,5,1)	1) Caso 3 - RNA(2,5,1) 2) SMAP
<b>Rio Guaporé</b>	1) Caso 2 - RNA(1,7,1) 2) Caso 3 - RNA(2,7,1)	1) Caso 2 - RNA(1,7,1) 2) Caso 1 - RNA(1,7,1)	1) Caso 3 - RNA(2,7,1) 2) Caso 2 - RNA(1,10,1)	1) Caso 1 - RNA(1,7,1) 2) Caso 2 - RNA(1,7,1)	1) Caso 3 - RNA(2,7,1) 2) Caso 2 - RNA(1,7,1)	1) SMAP 2) Caso 2 - RNA(1,7,1)	1) Caso 3 - RNA(2,7,1) 2) Caso 1 - RNA(1,7,1)	1) Caso 3 - RNA(2,7,1) 2) SMAP

A observação da **Tabela 5.21** revela que os modelos de baixo conteúdo de informação física sobre o processo de transformação chuva-vazão (Caso 1 e Caso 4) raramente figuram entre a dupla de modelos com melhores desempenhos, segundo qualquer dos critérios (apenas o Caso 1 aparece mais freqüentemente na bacia do rio Guarapiranga). Por exemplo, o ganho de informação produzido pelo conhecimento sobre a maneira de estimar a precipitação média na bacia por Thiessen (considerada no Caso 1 – RNA(1,3,1)) em relação ao cálculo direto com base nas precipitações dos diversos postos (considerada no Caso 4 – RNA (2,3,1)) se traduziu no aumento do coeficiente de correlação entre valores calculados e observados que passou de 0.55 (Caso 4 - RNA(2,3,1), **Tabela 5.9**) para 0.73 (Caso 1 – RNA(1,3,1), **Tabela 5.9**).

A partir das informações da **Tabela 5.21** foi feito um estudo de freqüência, contabilizando o número de critérios segundo os quais o modelo figura na “1ª ou 2ª colocação”. Desta forma construiu-se a **Tabela 5.22**, onde se mostram os resultados e os dois melhores modelos em cada bacia, entendendo por “melhor(es)” aquele(s) que satisfaz(em) um maior número de critérios. Nesta tabulação de resultados verifica-se uma maior dispersão dos modelos em relação à uma possível identificação de um melhor modelo no caso da bacia do rio Guarapiranga. Nos demais casos a predominância é mais nítida, mantendo a tendência já apontada previamente quanto aos melhores resultados sendo conseguidos nos modelos com maior conteúdo de informação sobre os processos físicos do ciclo hidrológico.

**Tabela 5.23 – Modelos de Melhor Desempenho para Cada Bacia – Etapa de Validação**

Bacia	Modelo	Número de critérios segundo os quais o modelo figura na condição de "1ª ou 2ª colocação"	Melhores Modelos
<b>Rio Itapetininga</b> (1524 Km <sup>2</sup> )	SMAP	7	SMAP
	Caso 3 – RNA (2,3,1)	4	Caso 3 – RNA (2,3,1)
	Caso 3 – RNA (2,7,1)	2	
	Caso 2 – RNA (1,7,1)	2	
	Caso 4 – RNA (2,3,1)	1	
<b>Rio das Almas</b> (495 Km <sup>2</sup> )	Caso 3 – RNA (2,7,1)	7	Caso 3 – RNA (2,7,1)
	SMAP	6	SMAP
	Caso 2 – RNA (1,3,1)	2	
	Caso 2 – RNA (1,7,1)	1	
<b>Rio Guarapiranga</b> (631 Km <sup>2</sup> )	Caso 2 – RNA (1,7,1)	3	Caso 2 – RNA (1,7,1)
	Caso 2 – RNA (1,5,1)	1	
	Caso 1 – RNA (1,3,1)	2	
	Caso 1 – RNA (1,7,1)	1	
	Caso 3 – RNA (2,5,1)	2	
	Caso 3 – RNA (2,7,1)	3	Caso 3 – RNA (2,7,1)
	SMAP	2	
<b>Rio Guaporé</b> (2504 Km <sup>2</sup> )	Caso 2 – RNA (1,7,1)	5	Caso 2 – RNA (1,7,1)
	Caso 3 – RNA (2,7,1)	5	
	Caso 1 – RNA (1,7,1)	3	Caso 3 – RNA (2,7,1)
	SMAP	2	

É ainda interessante explorar possíveis respostas à questão formulada na definição de objetivos desse trabalho de pesquisa sobre as situações, dentre as bacias estudadas, em que a técnica de previsão com as RNA's puras (sem combinação com SMAP) oferecem melhores resultados. Foi mencionado o relato da literatura segundo o qual o desempenho das RNA seria melhor do que outras técnicas preditivas para situações em que predominavam efeitos de natureza

não linear no equacionamento dos fenômenos. Assim, na **Tabela 5.24** são comparados os valores da raiz quadrada da variância dos resíduos (RMSE) como indicador da qualidade preditiva, para as diversas bacias, para o Caso 1 (RNA pura, sem qualquer combinação com o SMAP). Como o RMSE é uma variável que tem dimensão de vazão ( $m^3/s$ ), faz-se necessária uma adimensionalização para poder comparar bacias distintas, o que é indicado pela variável RMSEa (igual a RMSE dividido pela vazão média calculada no período). A última coluna dessa tabela indica a vazão de pico pela respectiva vazão de base (no início da ascensão) sendo tomados os valores do histórico da cheia mais preponderante (trecho de validação).

**Tabela 5.24 – Comparação dos RMSE de modelos RNA – Caso1 para Diferentes Bacias (Fase de Validação)**

<i>Bacia</i>	<i>RMSE</i> <i>(m<sup>3</sup>/s)</i>	<i>RMSEa</i>	<i>Modelo</i>	<i>Qpico/Qbase</i> <i>(observada)</i>
Guaporé (2.504 km <sup>2</sup> )	7.80	0.15	RNA(1,7,1)	1.6
Almas (495 km <sup>2</sup> )	2.46	0.31	RNA(1,3,1)	4.0
Guarapiranga (631 km <sup>2</sup> )	4.68	0.40	RNA(1,5,1)	4.2
Itapetininga (1.524 km <sup>2</sup> )	11.12	0.46	RNA(1,3,1)	5.1

Os resultados da **Tabela 5.24** fornecem as primeiras evidências de confirmação da hipótese de desempenho melhor dos modelos de RNA em situações de maior freqüência de não-linearidades do fenômeno subjacente à formação das hidrógrafas. Em termos adimensionais, os menores valores de RMSEa são encontrados nas bacias onde é menor a proporção  $Q_{pico}/Q_{base}$ , uma vez que o escoamento básico nestas situações, se processa com magnitude relativa maior (comparado a outras bacias) e, que portanto, nestas situações serão maiores os efeitos de natureza não linear. É claro que a generalidade destas indicações carece de estudos adicionais.

A magnitude dos valores de resíduos (RMSEa) obtidos nesse estudo, mesmo para o Caso 1, se equipara ou é inferior aos valores obtidos por HSU et al. (1995) com o uso de RNA para a bacia do Leaf river (1.949 Km<sup>2</sup>, Collins, Mississipi) na etapa de validação. Porém, no Caso 1, os valores de %VE são bastante superiores aos encontrados por HSU et al. (1995) e ligeiramente

---

superiores para o critério %MF. Cabe ressaltar que a metodologia empregada por esses autores foi diferente (*backpropagation*) e ainda, a simulação foi feita em intervalo diário.

Embora com metodologia distinta, o estudo aqui empreendido também confirma, de certa forma, a necessidade encontrada por SMITH e ELI (1995) ao utilizar algoritmo de RNA na representação chuva-vazão, quanto à sensível melhoria dos resultados da previsão se as informações de entrada e/ou saída dos dados observados forem submetidas a alguma depuração (filtragem) associada aos processos físicos subjacentes ao fenômeno, antes de serem submetidos à modelagem pela RNA. No estudo de SMITH e ELI (1995) a melhoria foi obtida pela formulação de uma hipótese quanto à representação da hidrógrafa de saída através de uma série de Fourier, sendo que o modelo de RNA se prestava então à previsão dos parâmetros da série de Fourier ao invés das vazões diretamente.

# CAPÍTULO VI

## CONCLUSÕES E RECOMENDAÇÕES

### 6.1 Conclusões

O estudo de redes neurais artificiais (RNA's) nesse trabalho teve como objetivo a busca de uma representação da relação chuva-vazão em bacias hidrográficas, em intervalo de discretização mensal. A motivação para o desenvolvimento da pesquisa se deu inicialmente com base nas vantagens da técnica de RNA relatadas na literatura, em especial, em virtude da calibração automática dos parâmetros, da maior eficiência na representação de processos em que estavam presentes relações não-lineares e da exigência de menor extensão da série histórica. Tais vantagens seriam muito relevantes na modelagem de sistemas hidrológicos, em especial, na relação chuva-vazão.

O modelo de redes neurais proposto tomou, dentre as várias arquiteturas de redes do tipo *perceptron* de múltiplas camadas (MLP – *multilayer perceptron*), topologias que apresentassem a melhor performance durante o treinamento e a validação, ambos supervisionados – por exemplo, o menor erro quadrático entre os dados observados e calculados. Os algoritmos aplicados no treinamento dessas redes também tiveram um papel importante na obtenção das melhores

respostas na simulação – por exemplo, determinação de mínimos global e maior velocidade de processamento – com base na função de ativação que desempenhou maior eficiência aplicada à redes do tipo MLP – algoritmos do tipo *backpropagation* (métodos convencionais) e algoritmos de segunda ordem (método do gradiente conjugado escalonado, método Quasi-Newton, método de Newton e outros).

Optou-se para o estudo de caso por redes MLP com topologias do tipo três camadas, com algoritmo de treinamento utilizando o método de gradiente escalonado, devido a grande capacidade de generalização e velocidade de processamento e também ao reduzido valor do resíduo das diferenças entre valores observados nas estações fluviométricos e os calculados pela RNA's na fase de calibração (aprendizado da rede).

O esforço empreendido na fase de desenvolvimento do modelo de RNA, com todas as variantes exploratórias (escolha do algoritmo mais eficiente, formulação da estrutura em três camadas, escolha da função de ativação, obtenção das melhores topologias, etc.) permite apontar uma primeira conclusão sobre um dos aspectos cogitados no início do trabalho, quanto à pretensa vantagem das RNA em virtude da calibração automática dos parâmetros. Com as devidas ressalvas face ao caráter exploratório inicial desse trabalho, não se evidenciam vantagens das RNA, em termos de facilidade de calibração e possibilidade de uso por pessoal de menor capacitação, em relação a outras técnicas de simulação do processo chuva-vazão. Em outras palavras, evita-se a “heurística da calibração dos parâmetros” dos modelos conceituais chuva-vazão em favor da “heurística” da estruturação do modelo de RNA.

Um aspecto que impediu um maior número de casos sendo estudados foi a limitação quanto à obtenção de bacias com informações hidrológicas completas, conforme seria requerido pelos estudos. A extensão da série histórica das variáveis - evaporação, chuva e vazão – que alimenta os modelos, foi um dos fatores limitantes na escolha das bacias, uma vez que, em algumas regiões, a quantidade das informações disponíveis hidrometeorológicas é bastante esparsa e apresentam densidade de estações (fluviométricas, pluviométricas e evaporimétricas) muito baixas.

Este fato demandou tempo de investigação, principalmente quando um dos critérios de seleção das bacias seria aquelas que tivessem séries extensas e com dados consistidos;

características físicas e tamanhos diferentes e que estivessem localizadas em regiões distintas, para que fossem testadas diversas situações, podendo assim, ser proposta generalização sobre as conclusões que se obteve. Estas dificuldades limitaram, em parte, o teste do modelo quanto as diversificação das localizações e características de bacias. Portanto, na seleção das bacias, procurou-se estabelecer o critério da existência de uma série de extensão mínima de 4 anos, com dados consistidos e área de drenagem superior a 300 Km<sup>2</sup>. Foram selecionadas as bacias hidrográficas dos rios Itapetininga, das Almas, Guarapiranga e Guaporé, as três primeiras localizadas no estado de São Paulo, na região Sudeste e a última no estado de Mato Grosso, na região Centro-Oeste do Brasil.

Após uma série de treinamentos da rede, variando-se a topologia, observou-se que a performance do modelo para séries hidrológicas muito pequenas, nos primeiros intervalos temporais não apresentam boa aderência dos dados. Isto decorre porque a RNA, para os primeiros pares de treinamentos, não ajusta bem, pois o processo de aprendizagem ocorre após um certo tempo – “tempo de aquecimento do modelo”, levando a resultados iniciais com alguns erros mais significativos. No entanto, o aspecto “extensão da série” não foi objeto de investigação o bastante para concluir sobre eventuais vantagens ou desvantagens da RNA em termos de desempenho, sobre outras técnicas.

Considerando um conjunto de critérios de análise, verifica-se, por comparação dos resultados, que o modelo SMAP e os modelos de RNA, que utilizam variáveis derivadas do SMAP (denominados Caso 2 e Caso 3), são o que fornecem melhor desempenho. Tais resultados evidenciam a importância da utilização do conhecimento e da correta formulação sobre os processos físicos que intervêm na transformação chuva-vazão e a respectiva incorporação deles nos modelos. Mesmo uma técnica robusta de extração de informação contida nos dados, como é a RNA, não prescinde desse tipo de conhecimento. Por outro lado, a combinação de alguma informação sobre o processo, como feito através do SMAP nesse trabalho, ou, através do uso das séries de Fourier em SMITH e ELI (1995) mais o uso da RNA, podem resultar ganhos substanciais na qualidade da modelagem, como se mostraram as duplas de melhores modelos em cada bacia (Tabela 5.23, em que os modelos combinados figuram como melhores em 06 ocorrências em um total de 08). Há indicações preliminares que estes ganhos sejam mais significativos em bacias em que sejam mais expressivas as relações não lineares do processo

chuva-vazão (maior área de drenagem, maior proporção do escoamento básico, mais translação das ondas, etc.).

## 6.2 Recomendações

A pesquisa revela uma perspectiva promissora da técnica de redes neurais artificiais para a modelagem da transformação chuva-vazão em bacias hidrográficas. Recomenda-se:

- A continuidade da pesquisa e a inclusão de investigação sobre o desempenho da técnica em bacias de diferentes grandezas e regiões, procurando identificar sob que situações os resultados da técnica de redes neurais artificiais são de melhor qualidade, em vista de sua capacidade para incorporar a complexa relação chuva-vazão dos processos hidrológicos;
- A utilização de outros algoritmos de treinamentos de RNA's e a verificação da eficiência do modelo aplicado às bacias hidrográficas sugeridas previamente;
- Estudos de técnicas que apresentem maior eficiência de partição do conjunto amostral em treinamento, validação e teste, garantindo a capacidade de generalização da rede;
- Orientar a RNA para incorporação dos processos físicos;
- Utilizar outros modelos para a comparação, bem como, aplicar séries diárias e,
- Simular o modelo para dividindo a série histórica em seguimentos considerando o período seco e período úmido.

## Anexo A - Programa Teste.m em Ambiente MATLAB®

```

% Este programa calcula os parâmetros sat, pes, crec para serem substituídos
% no programa teste12.m
% Teste.m
% 08/02/1999
%
% BACIA DO RIO GUARAPIRANGA (SP)
%
clear all;format compact;format long;
ind = 1;

load guareva.dat; % Carrega arquivo de dados de evaporação

cp=guareva;

load guarpre.dat; % Carrega arquivo de dados de precipitação
[m,n] = size(guarpre);
p=guarpre(:,2:n); % elimina a coluna de anos (primeira coluna)

load guarvaz.dat; % Carrega arquivo de dados de vazão
[m,n] = size(guarvaz);
qdes=guarvaz(:,2:n); % elimina a coluna de anos (primeira coluna)

med= 1.0e+10;

na = 40;ad = 631;tuin = 55;t05 = 3;ebin = 2.9;ecof = 1;pcof = 1;

disc = 10; %Intervalo de discretização dos parâmetros
tuin = tuin/100; % teor de umidade inicial

%Entrar com valores limites superior e inferior para sat, pes, e crec
satmax = 4000;satmin = 500;
pesmax = 9;pesmin = 1.4;
crecmax = 40;crecmin = 0.2;

for sat = satmin:((satmax-satmin)/(disc-1)):satmax,
    for pes = pesmin:((pesmax-pesmin)/(disc-1)):pesmax,
        for crec = crecmin:((crecmax-crecmin)/(disc-1)):crecmax,

% -----
% Ajuste de Unidades
% -----
crec = crec/100; % coeficiente de recarga
k = .5^(1/105); % coeficiente de recessão

% -----
% Inicialização (Instante 1)
% -----
rsolo = tuin * sat; % rsolo corresponde a rsolo(i)
rsub = ((ebin/(1-k))/ad)*2630; % rsub corresponde a rsub(i)

% -----

```

```

% Correção de Valores
% -----
soma = 0;
for y=1:na,      % loop anual
    for m=1:12,  % loop mensal
        prm = p(y,m) * pcof; % ajusta chuva média na bacia
        epm = ep(m)*ecof; % ajusta evaporação média na bacia
        tu = rsolo/sat; %calcula teor de umidade

        % Atualização prévia do teor de umidade

        dsol = .5*(prm - prm*(tu^pes) - epm*tu-rsolo*crec*(tu^4));
        tu = (rsolo + dsol)/sat;
        if tu > 1, % testa teor de umidade
            tu = 1;
        elseif tu < 0,
            tu = 0;
        end

        % -----
        % Cálculo das funções de transferência
        % -----

        es(y,m) = prm*(tu^pes); % calcula escoamento superficial
        er = epm*tu; % calcula evaporação real
        rec = (rsolo*crec)*(tu^4); % calcula recarga

        % -----
        % Cálculo da variável de saída atualizada
        % -----

        rsolop(y,m) = rsolo+prm-es(y,m)-er-rec; % atualiza reservatório solo
            % Corresponde rsolo(i+1)
        if rsolo > sat,
            er=es(y,m)+rsolop(y,m)-sat; % atualiza valor do escoa. superficial
            rsolop(y,m) = sat; % atualiza valor do rsolo
        elseif rsolo < 0,
            rsolop(y,m)=0;
        end
        rsolo = rsolop(y,m);

        % -----
        % Cálculo da função de transferência
        % -----

        eb(y,m) = rsub * (1-k); % calcula escoamento básico

        % -----
        % Cálculo da variável de estado atualizada
        % -----

        rsubp(y,m) = rsub - eb(y,m) + rec; % atualiza res. subt.
            % rsub corresponde r(i+1)
        rsub = rsubp(y,m);
        q(y,m) = ((es(y,m) + eb(y,m)) * ad) / 2630; % calcula vazões
    end
end
if norma(q-qdes) < med,
    satdef = sat;
    pesdef = pes;
    crecdef = crec;
    qdef = q;
    esdef = es;
    ebdef = eb;
    rsolopdef = rsolop;
    rsubpdef = rsubp;
    med = norma(q-qdes);
    meddef = med;
    dist(ind) = med; ind = ind+1;
    disp([sat pes crec med]);

```

---

```
        end
    end
end

%save caso2 es eb;
%save caso3 rsolop rsubp;
%save vazao q;
%save param satdef pesdef arecdef qdef esdef ebdef rsolopdef rsubpdef meddef;
plot(dist);
```

---

## Anexo B- Programa teste12.m

```

%Este programa calcula vazão (qdesdef), volumes dos reservatórios (rsolodef e rsubdef)
% e vazões dos escoamentos (ebdef e esdef),
% a partir dos parâmetros (pes, sat e crec) calculados no programa teste.mat
% Teste12.m
% 08/02/1999
%
%
clear all;format compact;format long;
ind = 1;

load guareva.dat; % Salva arquivos de entrada para o modelo Caso3
ep=guareva;

load guarpre.dat; % Carrega arquivo de dados de precipitação
[m,n] = size(guarpre);
p=guarpre(:,2:n); % elimina a coluna de anos (primeira coluna)

load guarvaz.dat; % Carrega arquivo de dados de vazão
[m,n] = size(guarvaz);
qdes=guarvaz(:,2:n); % elimina a coluna de anos (primeira coluna)

med= 1.0e+10;

% Entrar com número de anos da série (na); área (ad); teor de umidade inicial
% (tuin), escoamento básico inicial (ebin); coeficiente de ajuste da chuva média
% na bacia (pcof); coeficiente da evaporação média da bacia (ecof)

na = 40;ad = 631;tuin = 58;t05 = 2;ebin = 2.9;ecof = 1;pcof = 1;
disc = 10; % intervalo de discretização
tuin = tuin/100; % teor de umidade inicial

satmax = 4000;satmin = 500;
pesmax = 9;pesmin = 1.4;
crecmax = 40;crecmin = 0.2;

% Entrar com os valores de sat, pes e crec calculados no programa teste.m
for sat = 2820:((satmax-satmin)/(disc-1)):2820,
    for pes = 2.8:((pesmax-pesmin)/(disc-1)):2.8,
        for crec = 9.4:((crecmax-crecmin)/(disc-1)):9.4,

% -----
% Ajuste de Unidades
% -----
    crec = crec/100; % coeficiente de recarga
    k = .5^(1/t05); % coeficiente de recessão

% -----
% Inicialização (Instante 1)
% -----
    rsolo = tuin * sat; % rsolo corresponde a rsolo(i)
    rsub = ((ebin/(1-k))/ad)*2630; % rsub corresponde a rsub(i)

```

```

% -----
% Correção de Valores
% -----
soma = 0;
for y=1:na,      % loop anual
    for m=1:12,  % loop mensal
        prm = p(y,m) * pcof; % ajusta chuva média na bacia
        epm = ep(m)*ecof; % ajusta evaporação média na bacia
        tu = rsolo/sat; % calcula teor de umidade

        % Atualização prévia do teor de umidade

        dsol = .5*(prm - prm*(tu^pes) - epm*tu-rsolo*crec*(tu^4));
        tu = (rsolo + dsol)/sat;
        if tu > 1, % testa teor de umidade
            tu = 1;
        elseif tu < 0,
            tu = 0;
        end

        % -----
        % Cálculo das funções de transferência
        % -----

        es(y,m) = prm*(tu^pes); % calcula escoamento superficial
        er = epm*tu; % calcula evaporação real
        rec = (rsolo*crec)*(tu^4); % calcula recarga

        % -----
        % Cálculo da variável de saída atualizada
        % -----

        rsolop(y,m) = rsolo+prm-es(y,m)-er-rec; % atualiza reservatório solo
            % Corresponde rsolo(i+1)
        if rsolo > sat,
            er=es(y,m)+rsolop(y,m)-sat; % atualiza valor do escoa. superficial
            rsolop(y,m) = sat; % atualiza valor do rsolo
        elseif rsolo < 0,
            rsolop(y,m)=0;
        end
        rsolo = rsolop(y,m);

        % -----
        % Cálculo da função de transferência
        % -----

        eb(y,m) = rsub * (1-k); % calcula escoamento básico

        % -----
        % Cálculo da variável de estado atualizada
        % -----

        rsubp(y,m) = rsub - eb(y,m) + rec; % atualiza res. subt.
            % rsub corresponde r(i+1)
        rsub = rsubp(y,m);
        q(y,m) = ((es(y,m) + eb(y,m)) * ad) / 2630; % calcula vazões
    end
end

if norma(q-qdes) < med,
    satdef = sat;
    pesdef = pes;
    crecdef = crec;
    qdef = q;
    esdef = es;
    ebdef = eb;
    esc=es+eb;
    rsolopdef = rsolop;
    rsubpdef = rsubp;
    med = norma(q-qdes);
    meddef = med;

```

---

```
        dist(ind) = med; ind = ind+1;
        disp([sat pes crec med]);
    end
end
end

save caso2 es eb; % Salva vazões dos escoamentos superficiais e básicos
save caso2 -ascii es eb;

save soma2 esc; % Salva arquivos de entrada para o modelo Caso2
save soma2 -ascii esc;

%save caso3 rsolop rsubp; % Salva arquivos de entrada juntos para o modelo Caso3
%save caso3 -ascii rsolop rsubp;

save solo rsolop; % Salva arquivos de entrada separados para o modelo Caso3
save sub rsubp;

save solo -ascii rsolop; % Salva arquivos de entrada separados para o modelo Caso3
save sub -ascii rsubp;

save vazao q; % salva arquivos das vazões para comparação
save vazao -ascii q;

save param satdef pesdef crecdef qdef esdef ebdef rsolopdef rsubpdef rsubp meddef;
save param -ascii satdef pesdef crecdef qdef esdef ebdef rsolopdef rsubpdef rsubp meddef;

plot(dist);
```

—

## Anexo C – Programa Normaliz.m

```

% Programa Normaliz.m
% Pré-processamento da rede neural artificial
% Este programa normaliza os dados de entrada para a rede neural artificial
% no intervalo de [-1,1]
% Caso 1
% Bacia do rio Guarapiranga (SP)
% Período 1910/1950
% 09/02/99

clear all;format compact;format long;

load guarvaz.dat; %carrega arquivo das vazões mensais

[m,n] = size(guarvaz); % m e' o numero de linhas; n e' o numero de colunas
guarvaz = guarvaz(:,2:n); % elimina a coluna de anos (primeira coluna)

n = n-1;
vazao = reshape(guarvaz',m*n,1); % toma primeiro o transposto de arquivo
% e escreve o arquivo como sendo uma coluna

m=min(vazao);
M=max(vazao);

m_norma=-1;
M_norma=1;

A=vazao;
S_norm=m_norma+(A-m)/(M-m)*(M_norma-m_norma);

load guarpre.dat; %carrega arquivo das precipitações mensais

[m,n] = size(guarpre); % m e' o numero de linhas; n e' o numero de colunas
guarpre= guarpre(:,2:n); % elimina a coluna de anos (primeira coluna)

n = n-1;
preci = reshape(guarpre',m*n,1); % toma primeiro o transposto de arquivo e
% escreve o arquivo como sendo uma coluna

m=min(preci);
M=max(preci);

m_norma=-1;
M_norma=1;

Y=preci;
X_norm=m_norma+(Y-m)/(M-m)*(M_norma-m_norma);

% São 40 anos de dados: 30 para calibração e 10 para validação
% Separação das séries hidrológicas
% Vetor de dados para treinamento da rede (calibração): arquivo moller.m
X=X_norm(1:360); %lê os 360 primeiros dados do vetor coluna X_norm (1X48 - 3anos treino)
S=S_norm(1:360); %lê os 360 primeiros dados do vetor coluna S_norm (1X48)

save treino -ascii X S;

```

---

```
save dados X S;

%Vetor de dados para teste (validação): arquivo testam.m
X=X_norm(361:480); %lê os 120 últimos dados do vetor coluna X_norm (1X48 - 1 ano teste)
S=S_norm(361:480); %lê os 120 últimos dados do vetor coluna S_norm (1X48 - 1 ano teste)

save teste -ascii X S;
save dadtest X S;_
```

## Anexo D – Programa moller.m

```

% 31/10/1998
% moller.m
% Treinamento de rede perceptron com uma camada intermediaria
% Metodo de Optimizacao Irrestrita de 2a. ordem
% Algoritmo do Gradiente Conjugado e Escalonado
% Calculo exato da matriz hessiana (produto H*p)
% Resultados parcialmente baseados no artigo:
% Moller, M.F. A Scaled Conjugate Gradient Algorithm for
% Fast Supervised Learning, Neural Networks, 6:525-533, 1993.
% Excecoes:
% 1) introducao do calculo exato do produto H*p
% 2) refinamento do processo para calcular lamb em funcao de comp
% 3) calculo de beta pela formula original
% 4) calculo de comp pelo original
% 5) ajuste de pesos e' aceito apenas se comp > 0 (e nao >=)
% 6) lamb inicial = 0.0
% 7) (no. de iteracoes antes do reset de p) = 1.0*(no. de parametros)
% Obs:
% 1) Falta ver a questao da positivacao do delta (por que ??)
% 2) Verificar a questao do p_1
% Arquivo de dados para treinamento supervisionado:
% dados.mat, contendo X (matriz de entrada) e S (matriz de saida)
% Funcoes auxiliares:
% inic.m / processa.m / norma.m / hprocess.m / gravainf.m
%
%
clear all;format long;format compact;
%
% Norma minima admitida para o vetor gradiente
limiar = 1.0e-6;
taxa0 = 0.25;
taxa = taxa0;
corte = 0.25;
it1 = 0; % para lamb
it2 = 0; % para comp
% Parametro de escalamento para positivacao da hessiana (coeficiente Levenberg-Marquardt)
it1 = it1+1;lamb(it1) = 0.0;
blamb = 0;
m = 2; % Dimensao do vetor de entradas
n = [7;1]; % Dimensao da rede neural (camadas intermediaria e de saida)
[w1,w2,eq,stw1,stw2,niter,nflops] = inic(n,m); % w1:n(1)x(m+1) w2:n(2)x(n(1)+1)
%
% Carregamento dos dados para treinamento (e' assumido que o intervalo de
% valores para os dados esta' adequado. Caso contrario, e' necessario submeter
% os dados a um pre-processamento antes de prosseguir a partir deste ponto.
load dados; % X (matriz de entrada Nxm) e S (matriz de saida Nxn(2))
%
N = length(X(:,1));disp(sprintf('Numero de padroes = %d',N));
npesos = n(1)*(m+1)+n(2)*(n(1)+1);disp(sprintf('Numero de pesos da rede neural = %d',npesos));
[Ew,dEw] = processa(X,S,w1,w2,n,m,N);
eq = [eq;Ew];disp(sprintf('Erro quadratico inicial = %.12g',Ew));
itermenor = 1;

```



```

% function [w1,w2,eq,stw1,stw2,niter,nflops] = inic(n,m)
% m = no. de entradas
% n = no. de neuronios nas camadas intermediaria e de saida -> n = [n(1);n(2)]
% w1, w2: matrizes de pesos (por camada)
% w1:n(1)x(m+1) w2:n(2)x(n(1)+1)
% Tipos de geracao de pesos:
% Opcao 1 -> iniciar o treinamento
% Opcao 2 -> reiniciar o treinamento com a mesma condicao inicial
% Opcao 3 -> reiniciar o treinamento a partir da ultima atualizacao de pesos
%
function [w1,w2,eq,stw1,stw2,niter,nflops] = inic(n,m)
disp('(1) Gera w10 e w20 e salva');
disp('(2) Copia w10 e w20 existentes');
disp('(3) Copia w1 e w2 existentes');
resp = input('Tipo de geracao de pesos: ');
if resp == 1;
    w1 = -0.1 + 0.2*rand(n(1),m+1);
    w2 = -0.1 + 0.2*rand(n(2),n(1)+1);
    save w10 w1;save w20 w2;
    eq = [];stw1 = [];stw2 = [];niter = 0;nflops = 0;
elseif resp == 2;
    load w10;load w20;
    eq = [];stw1 = [];stw2 = [];niter = 0;nflops = 0;
elseif resp == 3;
    load w1;load w2;
    load evol;
else
    error('Opcao invalida!');
end
flops(0);

```

## 2 – processa.m

```

%
% function [Ew,dEw] = processa(X,S,w1,w2,n,m,N)
% Fornece o erro quadratico na saida e o vetor gradiente
% Metodo de apresentacao dos padroes em lote (batelada)
% Todos os neuronios apresentam entrada de polarizacao
%
function [Ew,dEw] = processa(X,S,w1,w2,n,m,N)
x1 = [X ones(N,1)];
y1 = tanh(x1*w1);
x2 = [y1 ones(N,1)];
% y2 = tanh(x2*w2);
y2 = x2*w2;
erro = y2-S;
% erro2 = erro.*(1.0-y2.*y2);
erro2 = erro;
dw2 = erro2*x2;
erro1 = (erro2*w2(:,1:n(1))).*(1.0-y1.*y1);
dw1 = erro1*x1;
verro = reshape(erro,N*n(2),1);
Ew = 0.5*(verro*verro);
% Se fosse utilizar EQM: Ew = sqrt((verro*verro)/(N*n(2)));
dEw = [reshape(dw1',n(1)*(m+1),1);reshape(dw2',n(2)*(n(1)+1),1)];

```

## 3 – norma.m

```

% 02/01/1998
% norma.m
% Fornece uma medida do tipo erro quadratico medio
%
function [E] = norma(S)

```

```
[nr,nc] = size(S);
E = sum(sum(S.*S));
E = sqrt(E/(nr*nc));
```

#### 4 – hprocess.m

```
%
% function [s] = hprocess(X,S,w1,w2,p1,p2,n,m,N)
% s = produto H*p calculado exatamente
%
function [s] = hprocess(X,S,w1,w2,p1,p2,n,m,N)
x1 = [X ones(N,1)];
rx1 = zeros(N,m+1);
y1 = tanh(x1*w1);
ry1 = (x1*p1'+rx1*w1).*(1.0-y1.*y1);
x2 = [y1 ones(N,1)];
rx2 = [ry1 zeros(N,1)];
% y2 = tanh(x2*w2);
y2 = x2*w2;
% ry2 = (x2*p2'+rx2*w2).*(1.0-y2.*y2);
ry2 = x2*p2'+rx2*w2;
erro = y2-S;
% erro2 = erro.*(1.0-y2.*y2);
erro2 = erro;
erro2 = ry2;
rw2 = erro2'*rx2+erro2'*x2;
erro1 = (erro2*w2(:,1:n(1))).*(1.0-y1.*y1);
erro1 = (erro2*w2(:,1:n(1))+erro2*p2(:,1:n(1))).*(1.0-y1.*y1)+(erro2*w2(:,1:n(1))).*(-2*y1.*ry1);
rw1 = erro1'*rx1+erro1'*x1;
rEw = [reshape(rw1',n(1)*(m+1),1),reshape(rw2',n(2)*(n(1)+1),1)];
s = rEw;
```

#### 5 – gravinf.m

```
% 08/11/1998
% gravainf.m
%
nflops = nflops+flops;
flops(0);
disp(sprintf('No. de flops = %.12g',nflops));
disp(sprintf('Erro quadratico atual = %.12g',eq(niter)));
disp(sprintf('No. de iteracoes = %d',niter));
save w1 w1;
save w2 w2;
save evol eq stw1 stw2 niter nflops lamb comp;
```

## Anexo E – Programa Testarn1.m

```

% 14/11/1998
% Verificação do desempenho da rede neural treinada
% Utilização dos pesos obtidos após o treinamento da rede neural
% Saída de dados treinados pós-processados (arquivo: calibrado)
% Apresentação dos resultados gráficos
% DADOS DE TREINAMENTO
% Testarn1.m
%
clear all;format compact;format long;

load w1;load w2;load dados;load evol; % Carrega pesos, dados para treinamento
      % que foram gerados no programa normaliza.m e evolu

N = length(X(:,1));
X = [X ones(N,1)];
n = length(w1(:,1));
r = length(w2(:,1));
m = length(w1(1,:))-1;

disp(sprintf('No. de padroes de treinamento = %d',N));
disp(sprintf('No. de neuronios na camada intermediaria = %d',n));
disp(sprintf('No. de iteracoes realizadas = %d',niter));
disp(sprintf('No. de flops = %d',nflops));

Srn = [tanh(X*w1') ones(N,1)]*w2';
verro = reshape(S-Srn,N*r,1);
eqf = 0.5*(verro'*verro);

disp(sprintf('Erro quadratico final = %.12g',eqf));

ro = (100/N)*sum(abs(S-Srn)./S);
disp(sprintf('Erro final (Rosangela)= %.12g',ro));

for k=1 :r,
    figure(k);subplot(111);plot(S(:,k),'r');hold on;plot(S(:,k),*r');
    plot(Srn(:,k),'g');plot(Srn(:,k),*g');hold off;
    title('Des (r) RN (g)');

```

---

```

end

for k=(r+1):(r+r),
    figure(k);subplot(111);plot(S(:,k-r)-Srn(:,k-r),'r');
    hold on;plot(S(:,k-r)-Srn(:,k-r),'*g');hold off;
    title('Erro = S-Srn');
end

for k=1:r,
    Smedio(1,k) = (1/N)*S(:,k)*ones(N,1);
end

den = 0; num = 0;

for l=1:N,
    for k=1:r,
        num = num+(S(l,k)-Srn(l,k))^2;
        den = den+(S(l,k)-Smedio(1,k))^2;
    end
end

% Desnormalização dos dados de saída da rede (TREINAMENTO)

load guarvaz.dat; %arquivo de dados das vazões normalizadas

[m,n] = size(guarvaz); % m e' o numero de linhas; n e' o numero de colunas
guarvaz = guarvaz(:,2:n); % elimina a coluna de anos (primeira coluna)

n = n-1;
vazao = reshape(guarvaz',m*n,1); % toma primeiro o transposto de arquivo e
    % escreve o arquivo como sendo uma coluna

m=min(vazao);
M=max(vazao);

m_norma=-1;
M_norma=1;

calib=((M-m)*(Srn-m_norma))/(M_norma-m_norma) + m; % Expressão para desnormalizar
    % as vazões treinadas

save calibrado -ascii calib; % Salva arquivo de dados das vazões treinadas do
    % do modelo calibrado

fvu = num/den;
disp(sprintf('FVU = %.12g',fvu));
figure(r+r+1);subplot(111);plot(eq);title('Erro Quadrático');
%figure(r+r+2);subplot(111);plot(eq1);title('Rosangela');

```

---

```
figure(r+r+3);subplot(211);plot(stw1);title('Delta pesos');subplot(212);plot(stw2);
```

## Anexo F - Programa Testarn.m

```

% 14/11/1998
% Verificação do desempenho da rede neural treinada
% Utilização dos pesos obtidos após o treinamento da rede neural
% Apresentação dos resultados gráficos
% DADOS DE TESTE
% Testarn.m

clear all;format compact;format long;

load w1;load w2;load dadtest;load evol; % Carrega pesos, dados para teste
      % que foram gerados no programa normaliza.m e evolui

N = length(X(:,1));
X = [X ones(N,1)];
n = length(w1(:,1));
r = length(w2(:,1));
m = length(w1(1,:))-1;

disp(sprintf('No. de padroes de treinamento = %d',N));
disp(sprintf('No. de neuronios na camada intermediaria = %d',n));
disp(sprintf('No. de iteracoes realizadas = %d',niter));
disp(sprintf('No. de flops = %d',nflops));

Srn = [tanh(X*w1) ones(N,1)]*w2';
verro = reshape(S-Srn,N*r,1);
eqf = 0.5*(verro*verro);

disp(sprintf('Erro quadratico final = %.12g',eqf));

ro = (100/N)*sum(abs(S-Srn)/S);
disp(sprintf('Erro final (Rosangela)= %.12g',ro));

for k=1:r,
    figure(k);subplot(111);plot(S(:,k),r');hold on;plot(S(:,k),'*r');
    plot(Srn(:,k),g');plot(Srn(:,k),'*g');hold off;
    title('Des (r) RN (g)');
end
for k=(r+1):(r+r),
    figure(k);subplot(111);plot(S(:,k-r)-Srn(:,k-r),r');
    hold on;plot(S(:,k-r)-Srn(:,k-r),'*g');hold off;
    title('Erro = S-Srn');
end
for k=1:r,
    Smedio(1,k) = (1/N)*S(:,k)*ones(N,1);
end
den = 0;num = 0;
for l=1:N,
    for k=1:r,
        num = num+(S(l,k)-Srn(l,k))^2;
        den = den+(S(l,k)-Smedio(1,k))^2;
    end
end
end

```

---

```
%Desnormalizacao dos dados de saida da rede (TESTE)

load guarvaz.dat; %arquivo de dados das vazões normalizadas

[m,n] = size(guarvaz); % m e' o numero de linhas; n e' o numero de colunas
guarvaz = guarvaz(:,2:n); % elimina a coluna de anos (primeira coluna)

n = n-1;
vazao = reshape(guarvaz',m*n,1); % toma primeiro o transposto de arquivo e escreve o arquivo como sendo uma coluna

m=min(vazao);
M=max(vazao);

m_norma=-1;
M_norma=1;

valid=((M-m)*(Srn-m_norma))/(M_norma-m_norma) + m; % Expressão para desnormalizar
% as vazões testadas

save validado -ascii valid; % Salva arquivo de dados das vazões testada do
% do modelo testado

fvu = num/den;
disp(sprintf('FVU = %.12g',fvu));
figure(r+r+1);subplot(111);plot(eq);title('EQ');
%figure(r+r+2);subplot(111);plot(eq1);title('Rosangela');
figure(r+r+3);subplot(211);plot(stw1);title('Delta pesos');subplot(212);plot(stw2);
```

---

## Anexo G – Arquivo de Dados do Programa SMAP v.99

### Arquivo de Dados Comentado

Linha 1	número de anos, <b>na</b> ; mês inicial do ano hidrológico
Linha 2	área de drenagem, <b>ad</b> ; nome do rio
Linha 3 a n	12 valores de vazão (em m <sup>3</sup> /s), <b>qdes(y,m)</b>
Linha n+1	<b>ecof</b> (Coeficiente de ajuste de evaporação média da bacia, <b>ad</b> ), nome do posto de evaporação
Linha n+2	12 valores de evaporação potencial (mm/mês), <b>ep(m)</b>
Linha n+3	<b>pcof</b> (Coeficiente de ajuste de chuva da bacia, <b>ad</b> ); número de postos de chuva; nome dos postos de chuva
Linha n+4	Coeficiente de Thiessen do posto de chuva; comentário
Linha n+5 a m	Ano; 12 valores de chuva (mm/mês), <b>p(y,m)</b>

Repete-se o conjunto de linha (n+4) pelo número de postos de chuva indicado na linha n+3

m64065c1 - Bloco de notas												
Arquivo Editar Exibir Ajuda												
A 10												
1524 rio Itapetininga (640650) - SE-006												
73	21.78	26.69	34.97	58.86	37.86	58.16	36.84	28.94	22.54	19.26	14.39	13.57
74	14.82	9.55	28.21	25.7	29.92	28.85	14.34	12.67	11.63	12.58	6.5	6.89
75	11.14	13.02	38.66	34.62	35.48	43.81	34.88	23.63	44.68	35.3	26.41	28.84
76	28.64	22.27	19.98	28.63	34.47	24.87	36.95	19.6	17.1	15.18	12.52	12.32
1.00 Jurumirim (E6-006M) - med 73/86												
141	158	154	157	131	138	183	78	63	79	97	109	
Ferreira das Almas (.42) + Usina Batista (.47) + Bairro Rib. Bonito (.11)												
0.42 Ferreira das Almas (E5-047)												
73	181	146	231	231	124	286	35	48	189	17	14	45
74	147	75	167	76	128	138	14	26	18	78	36	62
75	112	19	188	215	266	189	74	158	82	185	72	169
76	185	119	149	289	165	149	69	26	15	51	7	48
0.47 Usina Batista (E-028)												
73	155	123	308	278	59	282	128	8	185	3	12	23
74	164	68	256	92	288	58	8	26	11	59	28	75
75	118	181	194	156	299	188	78	164	68	189	184	142
76	159	88	95	388	128	282	119	12	48	59	4	64
0.11 Bairro Rib. Bonito (E4-132)												
73	164	177	323	436	186	315	74	24	186	8	36	31
74	188	188	328	163	249	97	33	42	15	77	24	69
75	132	238	162	335	316	223	119	198	82	151	138	177
76	188	99	143	383	92	173	92	32	49	36	17	123



valor minimo da funcao objetivo = 4,867

Analise de Sensibilidade dos Parametros:

sat:	pes:	x funcao objetivo							
1000	1 2 3 4 6 8 10								
crec:									
1	15 7 4 3 2 2 2								
2	15 7 4 2 2 2 2								
4	15 6 3 2 1 1 1								
8	15 6 3 2 1 1 1								
16	15 6 3 2 1 1 1								
32	15 6 3 2 2 2 3								
64	15 7 5 4 4 5 5								

crec:	pes:	x funcao objetivo							
8	1 2 3 4 6 8 10								
sat:									
500	14 7 4 3 3 3 4								
1000	15 6 3 2 1 1 1								
1500	16 7 3 2 1 1 1								
2000	17 7 3 2 1 1 1								
2500	18 7 4 2 1 1 2								
3000	18 8 4 3 2 2 2								
4000	20 9 5 3 2 2 2								

pes:	sat:	x funcao objetivo							
10	500 1000 1500 2000 2500 3000 4000								
crec:									
1	7 2 2 2 2 2 2								
2	6 2 1 1 1 1 1								
4	5 1 1 1 1 1 1								
8	4 1 1 1 2 2 2								
16	2 1 2 3 3 4 6								
32	1 3 4 5 7 8 11								
64	2 5 7 9 11 13 17								

Serie calculada (m3/s): (mes inicial = 10 )  
 86 7,59 11,5 21,9 57,8 39,7 15,2 16 35,4 59,7 18,9 19 19,6  
 87 21 17,4 20,3 26,1 41,1 38,5 31,1 51 27,3 18,2 17,5 18,4  
 88 22 21,7 27,3 43,7 49,7 32,8 19,8 18,6 17,3 38,3 18,8 23,8

**B) Arquivo m64065v2**

MODELO SMAP versao 99 / Mensal

rio Itapetininga (640650) - 5E-006

posto de evaporacao - Jurumirim (E6-006M) - med 73/86  
 coeficiente de ajuste de evaporacao media na bacia ..... 1

3 postos de chuva - Ferreira das Almas (.42) + Usina Batista (.47) + Bairro Rib. Bonito (.11)  
 coeficiente de ajuste de chuva media na bacia ..... 1

periodo da calibracao = 89 / 91 mes inicial = 10  
 area de drenagem ..... 1524 km2

INICIALIZACAO: umidade do solo ..... 61 %

vazao basica ..... 4,7 m3/s

PARAMETROS: capacidade de saturacao do reservatorio do solo . 966 mm  
 parametro de escoamento superficial ..... 5,2  
 parametro de recarga subterranea ..... 15,4 %  
 constante de recessao do escoamento basico ..... 4 meses

RESULTADOS: (mm/ano)

potenc	evap chuva	umidade do solo	evap real	escoam superficial	recarga basico	escoam calculado	defluvio
mm	mm	%	mm	mm	mm	mm	mm
1400	1446	67 58 81	940	241	265	246	488

armazenamento do periodo = 19 mm

	calculada	observada
Vazao Media (m3/s)	23,55	24,92
Desvio Padrao	14,22	17,13

Regressao Linear:

Coef.Correlacao = 0,928      Vcal = 0,77 Vobs + 4,33

valor minimo da funcao objetivo = 2,305

Analise de Sensibilidade dos Parametros:

sat:	pes:	x funcao objetivo						
1000	1 2	3	4	6	8	10		
cree:								
1	16 6	3 3	3 3	4 4				
2	16 6	3 2	2 2	3 3				
4	16 6	3 2	2 2	2 2				
8	16 6	3 1	1 1	1 1				
16	16 6	3 1	1 1	1 1				
32	17 7	3 2	3 3	3 4				
64	18 8	6 6	7 8	8 9				

cree:	pes:	x funcao objetivo						
8	1 2 3	4	6	8	10			
sat:								
500	15 6	4 4	4 5	6				
1000	16 6	3 1	1 1	1 1				
1500	18 6	3 1	1 1	1 1				
2000	19 7	3 2	1 2	2 2				
2500	21 8	4 3	2 2	3 3				
3000	23 9	5 3	3 3	3 3				
4000	26 11	6 5	4 4	4 5				

pes:	sat:	x funcao objetivo						
6	500 1000	1500	2000	2500	3000	4000		
cree:								
1	6 3	2 2	2 2	2 2				
2	6 2	2 2	2 2	2 2				
4	5 2	1 1	1 1	1 2				
8	4 1	1 1	1 2	3 4				
16	2 1	2 4	5 7	11				
32	1 3	6 9	12 15	21				
64	1 7	12 16	21 26	36				

Serie calculada (m3/s):                      (mes inicial = 10 )  
 89 8,69 9,83 11,3 60,6 39,5 31,3 17,4 17,9 16 23,1 17 19

90 16,8 16,9 17,2 25,5 70 62,2 30,4 21,4 29 17,8 19,2 19,2  
 91 20,2 15,4 34,6 17,8 19,4 29,3 19,4 18,6 13,2 14,4 12,3 15,5

## H.2 – Bacia do Rio das Almas

### H.2.1 – Validação

MODELO SMAP versao 99 / Mensal

rio das Almas (64035) - 5E-004

posto de evaporacao - Jurumirim (E6-006M) - med 73/86  
 coeficiente de ajuste de evaporacao media na bacia ..... 1

2 postos de chuva - Barreiro (.79) + Bairro Cerrado (.21)  
 coeficiente de ajuste de chuva media na bacia ..... 1

periodo da calibracao = 78 / 80 mes inicial = 10  
 area de drenagem ..... 495 km<sup>2</sup>

INICIALIZACAO: umidade do solo ..... 48 %  
 vazao basica ..... 1,5 m<sup>3</sup>/s

PARAMETROS: capacidade de saturacao do reservatorio do solo . 890 mm  
 parametro de escoamento superficial ..... 1,9  
 parametro de recarga subterranea ..... 63,7 %  
 constante de recessao do escoamento basico ..... 2 meses

RESULTADOS : (mm/ano)

evap		chuva		umidade do solo		evap real		escoam superficial		recarga basico		escoam calculado		defluvio
potenc	mm	mm	mm	%	mm	mm	mm	mm	mm	mm	mm	mm	mm	mm
1400	1111	47	40	57	668	288	174	169	457					

armazenamento do periodo = -14 mm

	calculada	observada
Vazao Media (m <sup>3</sup> /s)	7,17	6,79
Desvio Padrao	4,01	3,48

Regressao Linear:  
 Coef.Correlacao = 0,917 Vcal = 1,05 Vobs + 0

valor minimo da funcao objetivo = 2,164

Serie calculada (m<sup>3</sup>/s): (mes inicial = 10)

78 4,47 12,2 6,73 6,19 5,41 3,87 4,53 7,64 2,24 3,85 5,47 6,97  
 79 7,39 7,23 6,42 13,6 16 7,83 7,31 4,53 6,53 6,67 6,14 6,86  
 80 4,36 3,67 9,6 24,1 7,41 7,54 8,58 5,2 6,32 7,21 3,65 4,34

### H.3 – Bacia do Rio Guarapiranga

#### H.3.1 – Validação

A) Arquivo m6229v1

MODELO SMAP versao 99 / Mensal

rio Guarapiranga em Barragem (62290SP)

posto de evaporacao - Jurumirim (E6-006M) (med. 73/96)  
 coeficiente de ajuste de evaporacao media na bacia ..... 1

1 postos de chuva - Barragem (P-12069)  
 coeficiente de ajuste de chuva media na bacia ..... 1

periodo da calibracao = 78 / 85 mes inicial = 10  
 area de drenagem ..... 631 km<sup>2</sup>

INICIALIZACAO: umidade do solo ..... 58 %  
 vazao basica ..... 2,9 m<sup>3</sup>/s

PARAMETROS: capacidade de saturacao do reservatorio do solo . 2820 mm  
 parametro de escoamento superficial ..... 2,8  
 parametro de recarga subterranea ..... 9,4 %  
 constante de recessao do escoamento basico ..... 2 meses

RESULTADOS: (mm/ano)

evap chuva		umidade do solo		evap escoam real superfic		recarga basico		escoam calculado		defluvio
potenc	mm	mm	%	mm	mm	mm	mm	mm	mm	mm
1354	1274	58	49	72	779	279	224	223	502	

armazenamento do periodo = -7 mm

	calculada	observada
Vazao Media (m <sup>3</sup> /s)	10,05	12
Desvio Padrao	5,68	7,45

Regressao Linear:  
 Coef.Correlacao = 0,658 Vcal = 0,5 Vobs + 4,02

valor minimo da funcao objetivo = 17,805

Analise de Sensibilidade dos Parametros:

sat:	pes:	x funcao objetivo						
2500	1	2	3	4	6	8	10	
cres:								
1	3	2	2	2	2	2	3	
2	3	2	1	1	2	2	2	
4	3	1	1	1	1	1	2	
8	3	1	1	1	1	1	1	
16	3	1	1	1	1	2	2	
32	3	2	2	2	2	3	3	
64	4	3	3	3	4	4	4	

cres:	pes:	x funcao objetivo						
8	1	2	3	4	6	8	10	
sat:								

500	3	2	2	2	2	3	3
1000	3	2	1	1	1	2	2
1500	3	2	1	1	1	1	1
2000	3	1	1	1	1	1	1
2500	3	1	1	1	1	1	1
3000	3	1	1	1	1	1	1
4000	3	1	1	1	1	2	2

pes: sat: x funcao objetivo  
 4 500 1000 1500 2000 2500 3000 4000

crec:

1	3	2	2	2	2	2	1
2	3	2	2	2	1	1	1
4	3	2	1	1	1	1	1
8	2	1	1	1	1	1	1
16	2	1	1	1	1	1	2
32	1	1	1	2	2	2	3
64	1	2	2	3	3	4	5

Serie calculada (m3/s): (mes inicial = 10)

78	6,65	16	11,6	9,17	11,6	7,85	7,18	4,71	4,24	3,77	5,08	5,25
79	5,61	6,88	6,77	8,32	10,6	16,1	8,83	7,74	4,34	6,12	5,15	4,81
80	6,92	5,72	8,74	13,4	12,3	6,59	9,87	9,25	5,81	7,02	6,29	4,8
81	7,26	9,6	12	8,65	13,4	15,7	12,3	6,94	7,96	17,4	7,06	8,27
82	9,71	12	14,3	18,7	17,4	27,1	23	23,3	23,5	29	12,1	10,8
83	15,4	21,9	14,8	26,7	21,7	9,5	10,7	12,5	11,7	6,31	6,67	10,7
84	9,08	5,05	6,99	8,19	7,97	15,6	7,7	7,14	5,77	4,43	3,85	4,47
85	6,41	4,12	5,5	4,24	7,38	12	11,9	5,26	7,43	3,68	5,04	7,84

C) Arquivo m6229v2

MODELO SMAP versao 99 / Mensal

rio Guarapiranga em Barragem (62290SP)

posto de evaporacao - Jurumirim (E6-006M) (med. 73/96)  
 coeficiente de ajuste de evaporacao media na bacia ..... 1

1 postos de chuva - Barragem (P-12069)  
 coeficiente de ajuste de chuva media na bacia ..... 1

periodo da calibracao = 86 / 93 mes inicial = 10  
 area de drenagem ..... 631 km2

INICIALIZACAO: umidade do solo ..... 58 %  
 vazao basica ..... 2,9 m3/s

PARAMETROS: capacidade de saturacao do reservatorio do solo . 2820 mm  
 parametro de escoamento superficial ..... 2,8  
 parametro de recarga subterranea ..... 9,4 %  
 constante de recessao do escoamento basico ..... 2 meses

RESULTADOS : (mm/ano)

evap	chuva	umidade	do solo	evap	escoam	real	superfic	recarga	escoam	basico	calculado	defluvio
potenc												
mm	mm	%	mm	mm	mm	mm	mm	mm	mm	mm	mm	mm
1354	1345	60	52	66	802	322	245	244	566			

armazenamento do periodo = -23 mm

	calculada	observada
Vazao Media (m3/s)	11,32	13,31
Desvio Padrao	5,09	6,91

Regressao Linear:  
 Coef. Correlacao = 0,794      Vcal = 0,59 Vobs + 3,53

valor minimo da funcao objetivo = 6,369

Analise de Sensibilidade dos Parametros:

sat: pes:      x funcao objetivo  
 1000 1 2 3 4 6 8 10  
 crec:  
 1 4 3 4 4 6 7 7  
 2 4 3 3 4 5 6 6  
 4 4 3 3 3 4 4 5  
 8 4 2 2 2 3 3 3  
 16 4 2 1 1 2 2 3  
 32 3 1 1 1 2 3 4  
 64 3 1 2 2 4 5 6

crec: pes:      x funcao objetivo  
 32 1 2 3 4 6 8 10  
 sat:  
 500 4 2 2 2 2 2 3  
 1000 3 1 1 1 2 3 4  
 1500 4 1 1 2 3 4 5  
 2000 4 2 2 3 4 5 6  
 2500 4 2 3 4 5 6 6  
 3000 4 3 3 4 6 7 7  
 4000 5 4 5 6 8 8 8

pes: sat:      x funcao objetivo  
 3 500 1000 1500 2000 2500 3000 4000  
 crec:  
 1 5 4 3 3 3 3 3  
 2 5 3 3 3 2 2 2  
 4 4 3 2 2 2 2 1  
 8 4 2 2 1 1 1 1  
 16 3 1 1 1 1 1 2  
 32 2 1 1 2 3 3 5  
 64 1 2 3 4 5 7 9

Serie calculada (m3/s):      (mes inicial = 10 )  
 86 5,54 11 12,7 15,4 14,9 9,76 9,01 20,5 20,7 6,25 7 9,34  
 87 8,86 9,25 12 16 21,9 17,9 14,1 18,9 9,7 7,37 6,9 8,09  
 88 14,2 11,2 24,1 27,2 22,3 18,5 10,7 10,2 9,85 19,5 8,37 10,7  
 89 10,2 9,48 11 17,5 10,4 12,6 7,46 7,46 6,19 12 6,99 6,73  
 90 7,64 7,44 8,17 15,9 15,4 25,6 13,5 7,95 9,67 7,14 8,03 8,61  
 91 11,3 10,6 13,7 9,62 11,5 20 5,62 8,72 4,66 5,75 6,25 9,9  
 92 10,4 10,6 13,2 16,1 20,1 14,7 8,26 10,6 8,12 6,09 7,94 13,1  
 93 12 6,17 6,13 12,4 17,4 9,9 7,76 5,69 6,33 5,57 3,9 3,79

## H.4 – Bacia do Rio Guaporé

### H.4.1 – Validação

MODELO SMAP

versao 99 / Mensal

rio Guapore - Pontes e lacerda (15050MT)

posto de evaporacao - Diamantino (med. 78/89)

coeficiente de ajuste de evaporacao media na bacia ..... 1

2 postos de chuva - Pontes e Lacerda (.78) + Alto Jauru (.22)

coeficiente de ajuste de chuva media na bacia ..... 0,98

periodo da calibracao = 77 / 78                      mes inicial = 10

area de drenagem ..... 2504 km<sup>2</sup>

INICIALIZACAO: umidade do solo ..... 46 %

vazao basica ..... 34,3 m<sup>3</sup>/s

PARAMETROS: capacidade de saturacao do reservatorio do solo . 1990 mm

parametro de escoamento superficial ..... 4,1

parametro de recarga subterranea ..... 23,2 %

constante de recessao do escoamento basico ..... 3 meses

RESULTADOS : (mm/ano)

evap chuva		umidade do solo		evap real		escoam superfic		recarga basico		escoam calculado		defluvio	
potenc	mm	mm	%	mm	mm	mm	mm	mm	mm	mm	mm	mm	mm
1665	1468	57	46	68	933	175	368	396	572				

armazenamento do periodo = -37 mm

	calculada	observada
Vazao Media (m <sup>3</sup> /s)	45,37	51,24
Desvio Padrao	12,45	11,6

Regressao Linear:

Coef. Correlacao = 0,826      Vcal = 0,89 Vobs + -0,05

valor minimo da funcao objetivo = 0,666

Analise de Sensibilidade dos Parametros:

sat:	pes:	x funcao objetivo							
3000	1	2	3	4	6	8	10		
crec:									
1	21	10	10	13	18	21	22		
2	21	9	9	11	15	18	20		
4	21	8	7	9	12	14	15		
8	20	6	5	6	8	10	10		
16	19	4	2	2	4	5	6		
32	19	2	0	1	3	4	4		
64	19	3	2	3	5	5	6		

crec:	pes:	x funcao objetivo							
32	1	2	3	4	6	8	10		
sat:									
500	31	18	13	10	8	7	7		
1000	24	9	4	3	2	3	3		
1500	21	5	2	1	2	3	4		

---

2000	20	4	1	1	2	3	4
2500	19	3	0	1	3	4	4
3000	19	2	0	1	3	4	4
4000	18	2	0	1	3	4	4

pes: sat: x funcao objetivo  
3 500 1000 1500 2000 2500 3000 4000

crec:

1	22	14	11	10	10	10	11
2	21	13	10	9	9	9	10
4	20	12	8	7	7	7	8
8	19	10	6	5	5	5	5
16	16	7	4	2	2	2	2
32	13	4	2	1	0	0	0
64	9	3	1	1	1	2	3

Serie calculada (m3/s): (mes inicial = 10 )  
77 39,1 44,6 45,7 53,7 77,1 73,2 58,2 50,4 51,4 41,9 39,4 37,8  
78 33,6 30,9 35,9 49,7 56,2 42,9 54 42,8 35,1 35,3 30,8 29,2

## Anexo I – Vazões Observadas e Vazões Calculadas –SMAPm e RNA's

### I.1 – Bacia do Rio Itapetininga

#### I.1.1 Modelo SMAPm

- Validação 1

**TABELA I.1 – Bacia do Rio Itapetininga – Vazões Médias Mensais Calculadas e Observadas – Validação 1 - Período 1986 a 1988 - m<sup>3</sup>/s**

<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
86	7,59	11,5	21,9	57,8	39,7	15,2	16	35,4	59,7	18,9	19	19,6
87	21	17,4	20,3	26,1	41,1	38,5	31,1	51	27,3	18,2	17,5	18,4
88	22	21,7	27,3	43,7	49,7	32,8	19,8	18,6	17,3	38,3	18,8	23,8
<i>Vazão Observada (m<sup>3</sup>/s)</i>												
86	8,6	11,3	35,43	45,88	67,04	23,39	16,08	27,91	50,8	29,75	17,61	16,18
87	15,28	13,22	18,23	16,8	25,94	43,84	29,12	29,1	42,09	20,56	14,84	12,01
88	15,5	23,42	19,57	65,8	51,28	45,43	22,31	17,3	15,17	18,02	39,73	24,66

- Validação 2

**TABELA I.2 – Bacia do Rio Itapetininga – Vazões Médias Mensais Calculadas e Observadas – Validação 2 - Período 1989 a 1991 - m<sup>3</sup>/s**

<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
89	8,69	9,83	11,3	60,6	39,5	31,3	17,4	17,9	16	23,1	17	19
90	16,8	16,9	17,2	25,5	70	62,2	30,4	21,4	29	17,8	19,2	19,2
91	20,2	15,4	34,6	17,8	19,4	29,3	19,4	18,6	13,2	14,4	12,3	15,5
<i>Vazão Observada (m<sup>3</sup>/s)</i>												
89	19,16	19,66	16,75	66,43	36,13	40,07	22,98	18,66	16,79	21,66	17,63	18,58
90	16,47	14,71	11,39	17,93	94,47	61,67	38,25	27,31	20,31	19,49	15,63	12,96
91	30,97	14,67	24,14	15,41	17,89	27,83	23,4	21,81	14,91	14,79	11,64	14,64

## I.1.2 Modelo RNA's

- Caso1

**TABELA I3 – Bacia do Rio Itapetininga – Caso1 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,3,1)- Período 1987 a 1991 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
87	15,28	13,22	18,23	16,8	25,94	43,84	29,12	29,1	42,09	20,56	14,84	12,01
88	15,5	23,42	19,57	65,8	51,28	45,43	22,31	17,3	15,17	18,02	39,73	24,66
89	19,16	19,66	16,75	66,43	36,13	40,07	22,98	18,66	16,79	21,66	17,63	18,58
90	16,47	14,71	11,39	17,93	94,47	61,67	38,25	27,31	20,31	19,49	15,63	12,96
91	30,97	14,67	24,14	15,41	17,89	27,83	23,4	21,81	14,91	14,79	11,64	14,64
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
87	19,69	16,96	23,88	28,58	33,32	26,88	21,12	30,63	16,31	12,30	12,09	15,96
88	24,63	22,46	27,84	55,57	32,39	21,40	14,37	14,50	14,44	35,90	14,75	19,52
89	18,20	19,95	21,40	64,40	28,33	22,96	14,95	15,75	14,63	21,88	15,61	18,44
90	17,19	19,35	21,03	30,63	50,50	56,29	18,44	14,37	19,95	12,57	14,95	17,19
91	20,57	15,41	40,38	16,74	19,78	29,08	17,26	16,89	12,62	14,75	13,35	21,22

**TABELA I4 – Bacia do Rio Itapetininga – Caso1 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,7,1)- Período 1987 a 1991 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
87	15,28	13,22	18,23	16,8	25,94	43,84	29,12	29,1	42,09	20,56	14,84	12,01
88	15,5	23,42	19,57	65,8	51,28	45,43	22,31	17,3	15,17	18,02	39,73	24,66
89	19,16	19,66	16,75	66,43	36,13	40,07	22,98	18,66	16,79	21,66	17,63	18,58
90	16,47	14,71	11,39	17,93	94,47	61,67	38,25	27,31	20,31	19,49	15,63	12,96
91	30,97	14,67	24,14	15,41	17,89	27,83	23,4	21,81	14,91	14,79	11,64	14,64
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
87	21,15	17,11	23,15	27,76	39,41	25,65	22,01	30,20	15,86	13,26	13,32	15,25
88	23,60	22,52	26,80	49,97	32,22	22,13	13,42	13,50	13,45	41,56	13,69	21,00
89	19,35	21,36	22,13	58,04	27,45	22,71	13,88	14,91	13,59	22,31	14,70	19,72
90	17,55	20,84	21,97	30,20	51,53	48,45	19,72	13,42	21,36	13,19	13,88	17,55
91	21,75	14,42	39,12	16,68	21,22	28,41	17,69	16,97	13,18	13,69	13,11	22,05

- Caso2

**TABELA I.5 – Bacia do Rio Itapetininga – Caso2 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,3,1)- Período 1987 a 1991 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
87	15,28	13,22	18,23	16,8	25,94	43,84	29,12	29,1	42,09	20,56	14,84	12,01
88	15,5	23,42	19,57	65,8	51,28	45,43	22,31	17,3	15,17	18,02	39,73	24,66
89	19,16	19,66	16,75	66,43	36,13	40,07	22,98	18,66	16,79	21,66	17,63	18,58
90	16,47	14,71	11,39	17,93	94,47	61,67	38,25	27,31	20,31	19,49	15,63	12,96
91	30,97	14,67	24,14	15,41	17,89	27,83	23,4	21,81	14,91	14,79	11,64	14,64
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
87	24,86	19,39	22,87	28,95	37,80	36,85	32,99	43,36	31,02	22,14	20,96	21,42
88	25,26	24,76	29,90	39,05	42,54	34,00	23,78	21,97	19,52	36,23	21,83	27,84
89	24,73	24,08	23,90	30,21	41,16	36,30	26,66	26,12	22,56	29,26	22,21	24,12
90	20,18	19,52	19,34	29,08	68,07	52,79	33,09	26,41	31,90	21,07	22,64	21,94
91	22,75	15,93	33,84	19,11	21,34	31,33	21,91	20,61	13,78	14,74	12,72	15,13

**TABELA I.6 – Bacia do Rio Itapetininga – Caso2 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,7,1)- Período 1987 a 1991 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
87	15,28	13,22	18,23	16,8	25,94	43,84	29,12	29,1	42,09	20,56	14,84	12,01
88	15,5	23,42	19,57	65,8	51,28	45,43	22,31	17,3	15,17	18,02	39,73	24,66
89	19,16	19,66	16,75	66,43	36,13	40,07	22,98	18,66	16,79	21,66	17,63	18,58
90	16,47	14,71	11,39	17,93	94,47	61,67	38,25	27,31	20,31	19,49	15,63	12,96
91	30,97	14,67	24,14	15,41	17,89	27,83	23,4	21,81	14,91	14,79	11,64	14,64
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
87	23,00	19,21	22,77	29,56	38,50	37,10	32,24	43,14	31,00	21,99	20,77	21,24
88	25,45	24,88	30,32	40,17	42,81	33,19	23,76	21,81	19,34	36,16	21,66	28,46
89	24,84	24,09	23,90	105,97	42,10	36,26	27,11	26,47	22,43	29,83	22,06	24,14
90	19,99	19,34	19,16	29,68	96,33	60,34	32,32	26,81	31,49	20,89	22,52	21,78
91	22,64	15,87	33,02	18,94	21,16	31,17	21,75	20,42	13,82	14,73	12,81	15,11

● Caso3

**TABELA I.7 – Bacia do Rio Itapetininga – Caso3 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (2,3,1)- Período 1987 a 1991 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
87	15,28	13,22	18,23	16,8	25,94	43,84	29,12	29,1	42,09	20,56	14,84	12,01
88	15,5	23,42	19,57	65,8	51,28	45,43	22,31	17,3	15,17	18,02	39,73	24,66
89	19,16	19,66	16,75	66,43	36,13	40,07	22,98	18,66	16,79	21,66	17,63	18,58
90	16,47	14,71	11,39	17,93	94,47	61,67	38,25	27,31	20,31	19,49	15,63	12,96
91	30,97	14,67	24,14	15,41	17,89	27,83	23,4	21,81	14,91	14,79	11,64	14,64
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
87	16,52	12,31	14,99	21,78	37,94	39,35	36,50	41,34	35,32	27,80	15,60	12,46
88	16,09	16,90	23,21	37,27	43,90	36,42	25,22	19,16	15,83	38,42	25,49	24,60
89	19,20	16,65	16,60	48,60	42,98	37,24	29,05	24,54	20,05	26,27	20,12	18,98
90	14,68	13,24	13,78	22,40	51,47	46,49	36,73	30,96	33,77	22,83	16,72	14,73
91	15,00	10,49	29,62	17,80	17,33	27,62	22,42	21,07	14,53	12,58	9,67	12,61

**TABELA I.8 – Bacia do Rio Itapetininga – Caso3 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (2,7,1)- Período 1987 a 1991 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
87	15,28	13,22	18,23	16,8	25,94	43,84	29,12	29,1	42,09	20,56	14,84	12,01
88	15,5	23,42	19,57	65,8	51,28	45,43	22,31	17,3	15,17	18,02	39,73	24,66
89	19,16	19,66	16,75	66,43	36,13	40,07	22,98	18,66	16,79	21,66	17,63	18,58
90	16,47	14,71	11,39	17,93	94,47	61,67	38,25	27,31	20,31	19,49	15,63	12,96
91	30,97	14,67	24,14	15,41	17,89	27,83	23,4	21,81	14,91	14,79	11,64	14,64
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
87	17,20	13,79	15,46	22,91	34,27	34,02	33,55	41,06	34,71	25,59	16,34	14,03
88	16,68	17,11	24,36	31,40	44,28	35,65	24,01	19,19	16,69	32,61	25,64	24,65
89	19,15	17,06	16,86	37,45	39,39	34,23	27,69	23,24	19,83	26,48	19,91	18,97
90	15,55	14,16	14,21	24,00	57,15	50,55	34,05	30,22	36,05	21,74	17,44	15,88
91	15,80	11,89	25,15	17,88	17,40	26,44	23,45	21,65	15,09	13,34	10,57	12,47

● Caso 4

**TABELA I.9 – Bacia do Rio Itapetininga – Caso4 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (2,3,1)- Período 1987 a 1991 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
87	15,28	13,22	18,23	16,8	25,94	43,84	29,12	29,1	42,09	20,56	14,84	12,01
88	15,5	23,42	19,57	65,8	51,28	45,43	22,31	17,3	15,17	18,02	39,73	24,66
89	19,16	19,66	16,75	66,43	36,13	40,07	22,98	18,66	16,79	21,66	17,63	18,58
90	16,47	14,71	11,39	17,93	94,47	61,67	38,25	27,31	20,31	19,49	15,63	12,96
91	30,97	14,67	24,14	15,41	17,89	27,83	23,4	21,81	14,91	14,79	11,64	14,64
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
87	16,75	16,75	16,77	16,81	16,78	16,78	16,75	16,90	16,80	12,53	6,37	16,79
88	27,83	27,13	37,65	34,02	30,98	16,84	17,64	13,19	19,10	36,77	11,34	15,92
89	18,51	17,33	18,47	41,98	24,71	24,58	15,36	17,29	12,27	28,51	19,36	17,02
90	16,75	16,79	16,75	31,53	41,98	34,04	24,67	17,89	17,37	12,47	19,64	16,89
91	21,93	23,71	41,98	18,96	19,29	24,83	17,43	19,85	17,55	16,95	15,57	22,19

**TABELA I.10 – Bacia do Rio Itapetininga – Caso4 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (2,7,1)- Período 1987 a 1991 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
87	15,28	13,22	18,23	16,8	25,94	43,84	29,12	29,1	42,09	20,56	14,84	12,01
88	15,5	23,42	19,57	65,8	51,28	45,43	22,31	17,3	15,17	18,02	39,73	24,66
89	19,16	19,66	16,75	66,43	36,13	40,07	22,98	18,66	16,79	21,66	17,63	18,58
90	16,47	14,71	11,39	17,93	94,47	61,67	38,25	27,31	20,31	19,49	15,63	12,96
91	30,97	14,67	24,14	15,41	17,89	27,83	23,4	21,81	14,91	14,79	11,64	14,64
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
87	9,57	16,40	22,28	-50,83	28,64	22,33	19,33	-21,49	16,93	13,32	15,09	15,41
88	21,11	21,30	22,95	38,43	47,14	21,46	12,82	11,69	12,16	26,45	12,14	18,96
89	18,75	20,99	21,75	50,45	34,61	25,12	12,12	13,80	13,12	21,33	13,17	20,52
90	21,11	22,25	20,06	39,12	43,74	34,77	20,64	12,83	20,78	12,57	12,72	19,14
91	21,45	16,75	36,86	16,11	18,42	98,48	18,37	15,98	11,54	14,59	11,41	21,14

## I.2 – Bacia do Rio das Almas

### I.2.1 Modelo SMAPm

- Validação 1

**TABELA I.11 – Bacia do Rio das Almas– Vazões Médias Mensais Calculadas e Observadas – Validação 1 - Período 1989 a 1991 - m<sup>3</sup>/s**

<i>Vazões Observadas (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
78	3,03	8,28	5,12	6,8	5,09	5,23	4,48	6,08	3,87	3,85	5,18	8,69
79	8,09	8,76	7,64	11,38	15,54	10,93	8,14	5,3	5,26	5,83	5,01	5,69
80	4,95	4,2	6,06	20,71	9,14	7,22	6,15	5,21	5,03	5,29	3,87	3,46
<i>Vazões Calculadas (m<sup>3</sup>/s)</i>												
78	4,47	12,2	6,73	6,19	5,41	3,87	4,53	7,64	2,24	3,85	5,47	6,97
79	7,39	7,23	6,42	13,6	16	7,83	7,31	4,53	6,53	6,67	6,14	6,86
80	4,36	3,67	9,6	24,1	7,41	7,54	8,58	5,2	6,32	7,21	3,65	4,34

### I.2.2 Modelo RNA's

- Casol

**TABELA I.12 – Bacia do Rio das Almas– Caso1 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,3,1)- Período 1978 a 1980 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
78	3,03	8,28	5,12	6,8	5,09	5,23	4,48	6,08	3,87	3,85	5,18	8,69
79	8,09	8,76	7,64	11,38	15,54	10,93	8,14	5,3	5,26	5,83	5,01	5,69
80	4,95	4,2	6,06	20,71	9,14	7,22	6,15	5,21	5,03	5,29	3,87	3,46
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	6,86	14,78	7,86	7,32	6,61	5,41	6,47	10,35	4,81	5,30	7,67	8,88
79	8,94	8,48	8,25	14,85	14,87	6,84	6,76	4,96	6,49	6,97	6,62	7,54
80	5,14	5,07	13,62	20,37	6,81	6,82	7,91	4,96	6,17	7,53	4,95	5,20

**TABELA I.13 – Bacia do Rio das Almas– Caso1 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,7,1)- Período 1978 a 1980 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
78	3,03	8,28	5,12	6,8	5,09	5,23	4,48	6,08	3,87	3,85	5,18	8,69
79	8,09	8,76	7,64	11,38	15,54	10,93	8,14	5,3	5,26	5,83	5,01	5,69
80	4,95	4,2	6,06	20,71	9,14	7,22	6,15	5,21	5,03	5,29	3,87	3,46
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	6,91	16,40	7,99	7,45	6,61	5,42	6,45	10,73	4,85	5,33	7,82	8,64
79	8,68	8,42	8,28	16,62	16,66	6,88	6,78	4,87	6,47	7,04	6,62	7,69
80	5,21	5,15	12,19	7,61	6,85	6,86	8,04	5,03	6,11	7,68	4,86	5,26

- Caso 2

**TABELA I.14 – Bacia do Rio das Almas– Caso2 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,3,1)- Período 1978 a 1980 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
78	3,03	8,28	5,12	6,8	5,09	5,23	4,48	6,08	3,87	3,85	5,18	8,69
79	8,09	8,76	7,64	11,38	15,54	10,93	8,14	5,3	5,26	5,83	5,01	5,69
80	4,95	4,2	6,06	20,71	9,14	7,22	6,15	5,21	5,03	5,29	3,87	3,46
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	4,59	12,16	8,24	6,20	5,30	4,26	4,77	10,98	5,54	5,05	6,69	8,92
79	8,67	7,55	6,91	16,91	16,29	9,10	8,42	5,31	6,22	7,06	6,68	7,08
80	4,33	3,71	9,44	18,11	9,22	7,92	8,20	5,88	6,40	7,83	4,38	4,00

**TABELA I.15 – Bacia do Rio das Almas– Caso2 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,7,1)- Período 1978 a 1980 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
78	3,03	8,28	5,12	6,8	5,09	5,23	4,48	6,08	3,87	3,85	5,18	8,69
79	8,09	8,76	7,64	11,38	15,54	10,93	8,14	5,3	5,26	5,83	5,01	5,69
80	4,95	4,2	6,06	20,71	9,14	7,22	6,15	5,21	5,03	5,29	3,87	3,46
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	5,99	8,33	7,62	7,16	6,46	5,19	5,69	9,12	3,39	5,02	6,84	8,01
79	8,40	8,11	7,90	19,18	16,66	8,73	8,48	5,59	7,24	7,37	6,98	7,55
80	5,31	4,72	7,80	14,82	8,17	8,14	8,96	5,85	6,82	7,72	4,37	5,12

● Caso 3

**TABELA I.16 – Bacia do Rio das Almas– Caso3 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (2,3,1)- Período 1978 a 1980 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
78	3,03	8,28	5,12	6,8	5,09	5,23	4,48	6,08	3,87	3,85	5,18	8,69
79	8,09	8,76	7,64	11,38	15,54	10,93	8,14	5,3	5,26	5,83	5,01	5,69
80	4,95	4,2	6,06	20,71	9,14	7,22	6,15	5,21	5,03	5,29	3,87	3,46
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	4,59	12,14	8,26	6,21	5,31	4,25	4,78	10,98	5,55	5,05	6,70	8,93
79	8,68	7,56	6,92	16,91	16,29	9,10	8,42	5,30	6,22	7,07	6,69	7,09
80	4,33	3,70	9,45	18,08	9,23	7,92	8,20	5,87	6,40	7,84	4,38	3,98

**TABELA I.17 – Bacia do Rio das Almas– Caso3 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (2,7,1)- Período 1978 a 1980 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
78	3,03	8,28	5,12	6,8	5,09	5,23	4,48	6,08	3,87	3,85	5,18	8,69
79	8,09	8,76	7,64	11,38	15,54	10,93	8,14	5,3	5,26	5,83	5,01	5,69
80	4,95	4,2	6,06	20,71	9,14	7,22	6,15	5,21	5,03	5,29	3,87	3,46
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	2,57	11,32	5,86	7,09	4,35	4,69	3,52	11,38	6,73	4,66	5,45	6,46
79	5,41	7,35	8,76	12,57	17,21	11,56	7,54	5,06	6,47	6,52	6,23	9,08
80	5,12	3,93	9,83	18,25	8,33	7,18	7,59	6,07	6,34	9,97	5,15	4,52

● Caso 4

**TABELA I.18 – Bacia do Rio das Almas– Caso4 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (2,3,1)- Período 1978 a 1980 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
78	3,93	8,28	5,12	6,8	5,09	5,23	4,48	6,08	3,87	3,85	5,18	8,69
79	8,09	8,76	7,64	11,38	15,54	10,93	8,14	5,3	5,26	5,83	5,01	5,69
80	4,95	4,2	6,06	20,71	9,14	7,22	6,15	5,21	5,03	5,29	3,87	3,46
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	6,94	14,23	7,41	7,06	6,70	8,88	6,63	8,98	4,53	5,91	7,16	8,28
79	8,32	8,20	7,32	14,79	14,42	6,88	10,01	4,74	6,80	7,05	6,74	7,45
80	5,66	5,36	13,67	19,78	6,85	6,71	7,72	5,48	6,62	7,28	4,74	5,67

**TABELA I.19 – Bacia do Rio das Almas– Caso4 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (2,7,1)- Período 1978 a 1980 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
78	3,93	8,28	5,12	6,8	5,09	5,23	4,48	6,08	3,87	3,85	5,18	8,69
79	8,09	8,76	7,64	11,38	15,54	10,93	8,14	5,3	5,26	5,83	5,01	5,69
80	4,95	4,2	6,06	20,71	9,14	7,22	6,15	5,21	5,03	5,29	3,87	3,46
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	12,91	6,62	9,62	7,51	5,89	5,64	5,70	12,64	4,98	5,01	7,86	15,03
79	15,43	12,18	10,79	17,83	22,12	6,08	28,39	5,07	5,37	6,05	5,80	7,31
80	5,09	5,88	6,75	18,44	6,69	6,61	8,79	4,94	5,17	7,87	5,00	5,22

### **I.3 – Bacia do Rio Guarapiranga**

#### **I.3.1 Modelo SMAPm**

**TABELA I.20 – Bacia do Rio Guarapiranga – Vazões Médias Mensais Calculadas e Observadas – Validação 1 - Período 1978 a 1985 - m<sup>3</sup>/s**

<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
78	6,65	16	11,6	9,17	11,6	7,85	7,18	4,71	4,24	3,77	5,08	5,25
79	5,61	6,88	6,77	8,32	10,6	16,1	8,83	7,74	4,34	6,12	5,15	4,81
80	6,92	5,72	8,74	13,4	12,3	6,59	9,87	9,25	5,81	7,02	6,29	4,8
81	7,26	9,6	12	8,65	13,4	15,7	12,3	6,94	7,96	17,4	7,06	8,27
82	9,71	12	14,3	18,7	17,4	27,1	23	23,3	23,5	29	12,1	10,8
83	15,4	21,9	14,8	26,7	21,7	9,5	10,7	12,5	11,7	6,31	6,67	10,7
84	9,08	5,05	6,99	8,19	7,97	15,6	7,7	7,14	5,77	4,43	3,85	4,47
85	6,41	4,12	5,5	4,24	7,38	12	11,9	5,26	7,43	3,68	5,04	7,84
<i>Vazão Observada (m<sup>3</sup>/s)</i>												
78	4,20	17,20	15,40	12,40	10,40	8,30	10,00	8,90	5,20	6,00	7,30	13,30
79	12,00	14,50	12,50	18,10	25,90	11,90	9,70	4,80	5,80	5,80	5,50	6,10
80	7,20	7,00	15,50	24,00	8,90	10,00	14,40	8,80	7,10	7,30	4,90	3,80
81	10,30	10,70	9,80	15,30	20,00	11,50	11,80	6,40	17,20	7,90	6,90	4,30
82	9,30	11,90	21,60	25,00	36,20	26,70	24,50	21,30	40,30	13,00	10,30	24,50
83	26,50	18,80	21,10	22,60	13,20	9,50	12,00	10,00	5,20	5,50	9,40	11,80
84	5,20	5,90	9,40	17,10	20,80	14,60	10,50	7,30	5,80	3,60	3,10	6,20
85	2,90	5,10	3,60	5,57	23,10	24,30	10,40	10,90	4,80	6,25	8,16	5,46

- Validação 2

**TABELA I.21 – Bacia do Rio Guarapiranga – Vazões Médias Mensais Calculadas e Observadas – Validação 2 - Período 1986 a 1993 - m<sup>3</sup>/s**

<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
86	5,54	11	12,7	15,4	14,9	9,76	9,01	20,5	20,7	6,25	7	9,34
87	8,86	9,25	12	16	21,9	17,9	14,1	18,9	9,7	7,37	6,9	8,09
88	14,2	11,2	24,1	27,2	22,3	18,5	10,7	10,2	9,85	19,5	8,37	10,7
89	10,2	9,48	11	17,5	10,4	12,6	7,46	7,46	6,19	12	6,99	6,73
90	7,64	7,44	8,17	15,9	15,4	25,6	13,5	7,95	9,67	7,14	8,03	8,61
91	11,3	10,6	13,7	9,62	11,5	20	5,62	8,72	4,66	5,75	6,25	9,9
92	10,4	10,6	13,2	16,1	20,1	14,7	8,26	10,6	8,12	6,09	7,94	13,1
93	12	6,17	6,13	12,4	17,4	9,9	7,76	5,69	6,33	5,57	3,9	3,79
<i>Vazão Observada (m<sup>3</sup>/s)</i>												
86	6,56	8,96	17,10	21,00	34,40	11,60	11,10	21,40	25,30	8,70	6,23	8,96
87	11,40	5,91	8,18	13,40	19,00	16,20	19,70	17,00	17,30	8,39	5,45	7,03
88	13,30	8,99	19,00	22,20	29,00	24,80	12,90	11,80	10,30	15,80	15,17	11,07
89	9,63	9,01	9,58	27,09	9,75	15,00	8,94	11,50	8,60	11,90	10,10	9,76
90	10,50	11,20	8,99	24,80	31,30	38,10	20,20	12,00	12,20	8,51	7,59	6,31
91	20,10	8,22	11,80	15,90	14,30	20,20	10,40	10,60	4,15	5,54	4,93	11,00
92	10,30	15,00	15,80	12,20	21,50	21,10	12,90	7,70	13,20	5,72	7,63	15,20
93	12,50	5,90	6,11	12,30	25,30	18,40	15,80	7,08	7,10	6,35	4,46	4,20

### I.3.2 Modelo RNA's

- Caso 1

**TABELA 5.22 – Bacia do Rio Guarapiranga – Caso1 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,5,1)- Período 1984 a 1993 - m³/s**

<i>Vazão Observada m³/s</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
84	5,2	5,9	9,4	17,1	20,8	14,6	10,5	7,3	5,8	3,6	3,1	6,2
85	2,9	5,1	3,6	5,57	23,1	24,3	10,4	10,9	4,8	6,25	8,16	5,46
86	6,56	8,96	17,1	21	34,4	11,6	11,1	21,4	25,3	8,7	6,23	8,96
87	11,4	5,91	8,18	13,4	19	16,2	19,7	17	17,3	8,39	5,45	7,03
88	13,3	8,99	19	22,2	29	24,8	12,9	11,8	10,3	15,8	15,17	11,07
89	9,63	9,01	9,58	27,09	9,75	15	8,94	11,5	8,6	11,9	10,1	9,76
90	10,5	11,2	8,99	24,8	31,3	38,1	20,2	12	12,2	8,51	7,59	6,31
91	20,1	8,22	11,8	15,9	14,3	20,2	10,4	10,6	4,15	5,54	4,93	11
92	10,3	15	15,8	12,2	21,5	21,1	12,9	7,7	13,2	5,72	7,63	15,2
93	12,5	5,9	6,11	12,3	25,3	18,4	15,8	7,08	7,1	6,35	4,46	4,2
<i>Vazão Calculada m³/s</i>												
84	5,42	9,24	11,66	11,72	20,90	10,24	9,39	7,75	5,89	5,01	6,47	8,32
85	7,04	10,05	8,57	15,65	17,60	19,60	8,24	10,01	5,21	7,06	10,54	8,17
86	8,37	15,16	17,73	19,81	18,30	10,38	9,63	17,61	19,77	5,53	5,75	8,24
87	8,33	9,42	13,42	19,74	25,60	19,31	12,30	17,98	8,14	5,83	5,34	7,19
88	14,93	11,15	33,86	33,63	19,65	15,06	8,35	7,94	7,89	18,87	6,81	9,15
89	9,16	9,16	11,32	18,50	10,87	13,70	8,35	8,55	7,32	13,99	8,31	8,11
90	9,42	9,62	10,85	17,86	19,70	32,56	12,16	7,57	8,75	6,31	7,51	8,51
91	11,54	11,26	17,14	10,70	13,29	20,12	6,41	9,43	4,97	6,63	7,67	12,06
92	12,76	12,94	17,93	19,64	17,58	14,55	8,17	9,99	7,89	5,78	8,25	14,34
93	12,46	6,85	7,30	18,32	17,90	11,16	9,14	6,91	7,86	7,09	4,96	5,19

**TABELA 5.23 – Bacia do Rio Guarapiranga – Caso1 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,7,1)- Período 1984 a 1993 - m³/s**

<i>Vazão Observada m³/s</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
84	5,2	5,9	9,4	17,1	20,8	14,6	10,5	7,3	5,8	3,6	3,1	6,2
85	2,9	5,1	3,6	5,57	23,1	24,3	10,4	10,9	4,8	6,25	8,16	5,46
86	6,56	8,96	17,1	21	34,4	11,6	11,1	21,4	25,3	8,7	6,23	8,96
87	11,4	5,91	8,18	13,4	19	16,2	19,7	17	17,3	8,39	5,45	7,03
88	13,3	8,99	19	22,2	29	24,8	12,9	11,8	10,3	15,8	15,17	11,07
89	9,63	9,01	9,58	27,09	9,75	15	8,94	11,5	8,6	11,9	10,1	9,76
90	10,5	11,2	8,99	24,8	31,3	38,1	20,2	12	12,2	8,51	7,59	6,31
91	20,1	8,22	11,8	15,9	14,3	20,2	10,4	10,6	4,15	5,54	4,93	11
92	10,3	15	15,8	12,2	21,5	21,1	12,9	7,7	13,2	5,72	7,63	15,2
93	12,5	5,9	6,11	12,3	25,3	18,4	15,8	7,08	7,1	6,35	4,46	4,2
<i>Vazão Calculada m³/s</i>												
84	5,50	9,15	11,78	11,85	20,59	10,22	9,30	7,65	5,92	5,14	6,45	8,21
85	6,98	10,02	8,46	15,60	17,31	19,46	8,13	9,97	5,31	6,99	10,55	8,06
86	8,26	15,16	17,50	19,83	18,06	10,38	9,56	17,44	19,83	5,60	5,79	8,14
87	8,22	9,34	13,56	19,82	25,67	19,11	12,45	17,74	8,03	5,86	5,43	7,12
88	14,96	11,23	33,81	33,73	19,77	15,07	8,24	7,84	7,79	18,63	6,76	9,06
89	9,07	9,07	11,42	18,62	10,93	13,83	8,24	8,44	7,24	14,09	8,20	8,01
90	9,34	9,55	10,89	17,48	19,80	32,43	12,31	7,48	8,65	6,31	7,42	8,40
91	11,66	11,36	16,96	10,73	13,43	19,74	6,39	9,35	5,10	6,60	7,58	12,20
92	12,92	13,09	17,70	19,76	17,32	14,61	8,06	9,95	7,79	5,83	8,14	14,41
93	12,62	6,79	7,22	18,07	17,51	11,24	9,04	6,85	7,76	7,03	5,09	5,29

## ● Caso2

**TABELA 5.24 – Bacia do Rio Guarapiranga – Caso2 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,5,1)- Período 1984 a 1993 - m<sup>3</sup>/s**

<i>Vazão Observada m<sup>3</sup>/s</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
84	5,2	5,9	9,4	17,1	20,8	14,6	10,5	7,3	5,8	3,6	3,1	6,2
85	2,9	5,1	3,6	5,57	23,1	24,3	10,4	10,9	4,8	6,25	8,16	5,46
86	6,56	8,96	17,1	21	34,4	11,6	11,1	21,4	25,3	8,7	6,23	8,96
87	11,4	5,91	8,18	13,4	19	16,2	19,7	17	17,3	8,39	5,45	7,03
88	13,3	8,99	19	22,2	29	24,8	12,9	11,8	10,3	15,8	15,17	11,07
89	9,63	9,01	9,58	27,09	9,75	15	8,94	11,5	8,6	11,9	10,1	9,76
90	10,5	11,2	8,99	24,8	31,3	38,1	20,2	12	12,2	8,51	7,59	6,31
91	20,1	8,22	11,8	15,9	14,3	20,2	10,4	10,6	4,15	5,54	4,93	11
92	10,3	15	15,8	12,2	21,5	21,1	12,9	7,7	13,2	5,72	7,63	15,2
93	12,5	5,9	6,11	12,3	25,3	18,4	15,8	7,08	7,1	6,35	4,46	4,2
<i>Vazão Calculada m<sup>3</sup>/s</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
84	6,00	8,41	10,25	9,87	20,19	9,13	8,23	6,72	5,50	5,00	5,47	6,14
85	5,24	6,47	5,39	8,41	14,42	13,74	6,00	7,85	4,70	5,64	8,28	6,23
86	6,21	10,75	12,55	16,05	15,64	9,54	8,76	21,20	21,30	6,42	7,14	9,59
87	9,15	9,65	13,23	18,48	21,58	20,50	16,35	21,06	10,59	7,99	7,53	8,77
88	16,75	12,62	26,03	35,30	22,07	20,98	12,06	11,37	10,93	21,29	9,18	12,11
89	11,39	10,50	12,46	20,42	11,62	14,71	8,17	8,20	6,94	13,88	7,71	7,43
90	8,38	8,18	8,96	19,02	18,48	32,49	15,91	8,75	10,77	7,84	8,84	9,44
91	12,90	11,97	16,28	10,69	13,25	21,38	6,44	9,62	5,65	6,57	7,00	11,07
92	11,73	11,97	15,51	19,25	21,38	17,60	9,04	11,94	8,90	6,84	8,71	15,41
93	13,87	6,90	6,88	14,42	20,38	11,05	8,48	6,47	7,07	6,36	5,08	5,01

**TABELA 5.25 – Bacia do Rio Guarapiranga – Caso2 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,7,1)- Período 1984 a 1993 - m<sup>3</sup>/s**

<i>Vazão Observada m<sup>3</sup>/s</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
84	5,20	5,90	9,40	17,10	20,80	14,60	10,50	7,30	5,80	3,60	3,1	6,2
85	2,90	5,10	3,60	5,57	23,10	24,30	10,40	10,90	4,80	6,25	8,16	5,46
86	6,56	8,96	17,10	21,00	34,40	11,60	11,10	21,40	25,30	8,70	6,23	8,96
87	11,40	5,91	8,18	13,40	19,00	16,20	19,70	17,00	17,30	8,39	5,45	7,03
88	13,30	8,99	19,00	22,20	29,00	24,80	12,90	11,80	10,30	15,80	15,17	11,07
89	9,63	9,01	9,58	27,09	9,75	15,00	8,94	11,50	8,60	11,90	10,1	9,76
90	10,50	11,20	8,99	24,80	31,30	38,10	20,20	12,00	12,20	8,51	7,59	6,31
91	20,10	8,22	11,80	15,90	14,30	20,20	10,40	10,60	4,15	5,54	4,93	11
92	10,30	15,00	15,80	12,20	21,50	21,10	12,90	7,70	13,20	5,72	7,63	15,2
93	12,50	5,90	6,11	12,30	25,30	18,40	15,80	7,08	7,10	6,35	4,46	4,2
<i>Vazão Calculada m<sup>3</sup>/s</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
84	5,86	8,53	10,39	10,02	20,06	9,27	8,33	6,69	5,25	4,63	5,22	6,02
85	4,93	6,40	5,12	8,53	14,36	13,72	5,85	7,93	4,24	5,43	8,39	6,12
86	6,10	10,88	12,61	15,87	15,49	9,69	8,89	21,47	21,68	6,35	7,16	9,73
87	9,29	9,80	13,24	18,22	22,09	20,45	16,16	21,23	10,73	8,09	7,59	8,90
88	16,54	12,67	24,91	36,65	22,26	21,10	12,14	11,48	11,06	21,66	9,32	12,19
89	11,50	10,64	12,52	20,34	11,72	14,63	8,27	8,31	6,94	13,85	7,78	7,48
90	8,50	8,28	9,10	18,78	18,22	32,09	15,75	8,88	10,91	7,92	8,97	9,59
91	12,94	12,06	16,10	10,83	13,26	21,38	6,36	9,77	5,44	6,51	7,01	11,19
92	11,83	12,06	15,37	19,02	21,90	17,35	9,17	12,03	9,03	6,82	8,84	15,27
93	13,84	6,89	6,86	14,36	20,29	11,18	8,60	6,40	7,08	6,28	4,73	4,64

## ● Caso 3

**TABELA 5.26 – Bacia do Rio Guarapiranga – Caso3 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (2,5,1)- Período 1984 a 1993 - m<sup>3</sup>/s**

<i>Vazão Observada m<sup>3</sup>/s</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
84	5,20	5,90	9,40	17,10	20,80	14,60	10,50	7,30	5,80	3,60	3,1	6,2
85	2,90	5,10	3,60	5,57	23,10	24,30	10,40	10,90	4,80	6,25	8,16	5,46
86	6,56	8,96	17,10	21,00	34,40	11,60	11,10	21,40	25,30	8,70	6,23	8,96
87	11,40	5,91	8,18	13,40	19,00	16,20	19,70	17,00	17,30	8,39	5,45	7,03
88	13,30	8,99	19,00	22,20	29,00	24,80	12,90	11,80	10,30	15,80	15,17	11,07
89	9,63	9,01	9,58	27,09	9,75	15,00	8,94	11,50	8,60	11,90	10,1	9,76
90	10,50	11,20	8,99	24,80	31,30	38,10	20,20	12,00	12,20	8,51	7,59	6,31
91	20,10	8,22	11,80	15,90	14,30	20,20	10,40	10,60	4,15	5,54	4,93	11
92	10,30	15,00	15,80	12,20	21,50	21,10	12,90	7,70	13,20	5,72	7,63	15,2
93	12,50	5,90	6,11	12,30	25,30	18,40	15,80	7,08	7,10	6,35	4,46	4,2
<i>Vazão Calculada m<sup>3</sup>/s</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
84	5,57	5,06	5,60	6,51	17,74	13,49	11,32	9,30	7,31	5,82	5,44	5,50
85	5,30	5,35	5,43	5,82	15,87	21,99	15,72	15,29	9,97	8,33	10,14	7,98
86	6,43	9,31	12,92	18,56	20,40	15,08	12,40	24,75	29,57	15,80	10,79	8,62
87	6,72	5,64	6,21	11,27	21,80	21,40	17,97	21,28	16,93	12,90	9,51	7,41
88	8,10	7,42	17,02	24,88	23,26	21,15	16,43	13,73	12,12	16,58	12,71	10,66
89	8,57	6,78	6,07	10,50	9,01	10,82	8,54	8,15	7,46	12,78	10,00	7,59
90	6,67	6,01	6,14	15,45	20,65	33,37	23,46	15,19	13,39	10,48	8,63	7,20
91	7,23	6,99	9,10	7,79	9,26	20,29	11,11	10,53	7,41	6,43	6,02	8,31
92	10,12	10,83	13,46	18,20	23,74	19,19	12,54	12,02	10,40	8,02	7,15	9,64
93	10,09	6,10	4,76	7,35	17,37	14,18	11,14	8,42	8,08	7,16	5,46	4,93

**TABELA 5.27 – Bacia do Rio Guarapiranga – Caso3 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (2,7,1)- Período 1984 a 1993 - m<sup>3</sup>/s**

<i>Vazão Observada m<sup>3</sup>/s</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
84	5,2	5,9	9,4	17,1	20,8	14,6	10,5	7,3	5,8	3,6	3,1	6,2
85	2,9	5,1	3,6	5,57	23,1	24,3	10,4	10,9	4,8	6,25	8,16	5,46
86	6,56	8,96	17,1	21	34,4	11,6	11,1	21,4	25,3	8,7	6,23	8,96
87	11,4	5,91	8,18	13,4	19	16,2	19,7	17	17,3	8,39	5,45	7,03
88	13,3	8,99	19	22,2	29	24,8	12,9	11,8	10,3	15,8	15,17	11,07
89	9,63	9,01	9,58	27,09	9,75	15	8,94	11,5	8,6	11,9	10,1	9,76
90	10,5	11,2	8,99	24,8	31,3	38,1	20,2	12	12,2	8,51	7,59	6,31
91	20,1	8,22	11,8	15,9	14,3	20,2	10,4	10,6	4,15	5,54	4,93	11
92	10,3	15	15,8	12,2	21,5	21,1	12,9	7,7	13,2	5,72	7,63	15,2
93	12,5	5,9	6,11	12,3	25,3	18,4	15,8	7,08	7,1	6,35	4,46	4,2
<i>Vazão Calculada m<sup>3</sup>/s</i>												
	<i>Out</i>	<i>Nov</i>	<i>Dez</i>	<i>Jan</i>	<i>Fev</i>	<i>Mar</i>	<i>Abr</i>	<i>Mai</i>	<i>Jun</i>	<i>Jul</i>	<i>Ago</i>	<i>Set</i>
84	5,76	5,37	5,76	6,70	17,82	13,43	11,26	9,31	7,43	5,98	5,47	5,37
85	4,34	4,20	3,09	4,85	13,95	20,90	15,83	15,51	10,35	8,72	10,56	8,40
86	6,69	9,80	13,25	18,72	20,56	14,95	12,24	24,79	29,25	16,19	10,45	8,29
87	6,72	5,91	6,23	11,07	21,75	21,67	18,53	22,10	17,20	12,77	9,49	7,70
88	7,79	7,20	17,19	25,38	24,01	21,66	16,69	13,90	12,16	16,77	12,61	10,49
89	8,50	7,03	6,20	10,31	8,81	10,62	8,37	8,01	7,39	12,56	9,83	7,55
90	6,74	6,16	6,33	15,57	20,72	33,07	23,88	15,49	13,35	10,13	8,31	7,04
91	7,03	6,87	8,92	7,68	9,12	20,17	10,93	10,34	7,28	6,43	6,11	8,35
92	10,12	10,81	13,34	18,03	23,73	19,48	12,53	11,93	10,14	7,72	6,96	9,44
93	9,89	6,12	5,32	7,43	17,26	13,95	10,95	8,34	8,06	7,23	5,62	4,82

## I.4 – Bacia do Rio Guaporé

### I.4.1 Modelo SMAPm

- Validação 1

**TABELA I.28 – Bacia do Rio Guaporé – Vazões Médias Mensais Calculadas e Observadas – Validação 1 - Período 1977a 1978 - m<sup>3</sup>/s**

<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
	<i>out</i>	<i>nov</i>	<i>dez</i>	<i>jan</i>	<i>fev</i>	<i>mar</i>	<i>abr</i>	<i>mai</i>	<i>jun</i>	<i>jul</i>	<i>ago</i>	<i>set</i>
77	39,1	44,6	45,7	53,7	77,1	73,2	58,2	50,4	51,4	41,9	39,4	37,8
78	33,6	30,9	35,9	49,7	56,2	42,9	54	42,8	35,1	35,3	30,8	29,2
<i>Vazão Observada (m<sup>3</sup>/s)</i>												
77	39,5	44,9	49,8	64,7	63,7	72,8	62,8	58,5	52,5	42,5	38,6	41,1
78	41,9	45,7	54,3	65,1	66,4	61	60,8	52,8	45,7	38	34,1	32,6

### I.4.2 Modelo RNA's

- Caso 1

**TABELA I.29 – Bacia do Rio Guaporé – Caso1 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,7,1)- Período 1977 a 1978 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>out</i>	<i>nov</i>	<i>dez</i>	<i>jan</i>	<i>fev</i>	<i>mar</i>	<i>abr</i>	<i>mai</i>	<i>jun</i>	<i>jul</i>	<i>ago</i>	<i>set</i>
78	39,5	44,9	49,8	64,7	63,7	72,8	62,8	58,5	52,5	42,5	38,6	41,1
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	47,73	48,95	57,65	76,47	73,66	49,35	55,62	46,97	43,24	44,42	43,00	45,63

**TABELA I.30 – Bacia do Rio Guaporé – Caso1 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,10,1)- Período 1977 a 1978 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>out</i>	<i>nov</i>	<i>dez</i>	<i>jan</i>	<i>fev</i>	<i>mar</i>	<i>abr</i>	<i>mai</i>	<i>jun</i>	<i>jul</i>	<i>ago</i>	<i>set</i>
78	39,5	44,9	49,8	64,7	63,7	72,8	62,8	58,5	52,5	42,5	38,6	41,1
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	47,55	48,91	57,66	77,70	73,65	49,35	55,72	46,71	43,62	44,30	43,51	45,32

- Caso2

**TABELA I.31 – Bacia do Rio Guaporé – Caso2 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,7,1)- Período 1977 a 1978 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>out</i>	<i>nov</i>	<i>dez</i>	<i>jan</i>	<i>fev</i>	<i>mar</i>	<i>abr</i>	<i>mai</i>	<i>jun</i>	<i>jul</i>	<i>ago</i>	<i>set</i>
78	39,5	44,9	49,8	64,7	63,7	72,8	62,8	58,5	52,5	42,5	38,6	41,1
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	37,78	36,35	39,89	62,99	68,19	47,54	62,41	47,18	37,27	37,97	34,84	34,50

**TABELA I.32 – Bacia do Rio Guaporé – Caso2 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (1,10,1)- Período 1977 a 1978 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>out</i>	<i>nov</i>	<i>dez</i>	<i>jan</i>	<i>fev</i>	<i>mar</i>	<i>abr</i>	<i>mai</i>	<i>jun</i>	<i>jul</i>	<i>ago</i>	<i>set</i>
78	39,5	44,9	49,8	64,7	63,7	72,8	62,8	58,5	52,5	42,5	38,6	41,1
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	37,60	34,82	41,00	60,72	69,35	48,80	60,33	48,52	36,65	37,94	31,56	30,81

● Caso 3

**TABELA I.33 – Bacia do Rio Guaporé – Caso3 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (2,7,1)- Período 1977 a 1978 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>out</i>	<i>nov</i>	<i>dez</i>	<i>jan</i>	<i>fev</i>	<i>mar</i>	<i>abr</i>	<i>mai</i>	<i>jun</i>	<i>jul</i>	<i>ago</i>	<i>set</i>
78	39,5	44,9	49,8	64,7	63,7	72,8	62,8	58,5	52,5	42,5	38,6	41,1
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	39,88	40,09	42,97	59,33	73,02	66,78	66,94	53,31	45,14	42,03	38,27	36,88

**TABELA I.34 – Bacia do Rio Guaporé – Caso3 - Vazões Médias Mensais Observadas e Calculadas – Validação Topologia (2,10,1)- Período 1977 a 1978 - m<sup>3</sup>/s**

<i>Vazão Observada (m<sup>3</sup>/s)</i>												
	<i>out</i>	<i>nov</i>	<i>dez</i>	<i>jan</i>	<i>fev</i>	<i>mar</i>	<i>abr</i>	<i>mai</i>	<i>jun</i>	<i>jul</i>	<i>ago</i>	<i>set</i>
78	39,5	44,9	49,8	64,7	63,7	72,8	62,8	58,5	52,5	42,5	38,6	41,1
<i>Vazão Calculada (m<sup>3</sup>/s)</i>												
78	40,29	40,71	43,15	59,59	73,66	66,55	66,72	54,74	44,07	42,01	38,50	36,97

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABELÉM, A. J. G. *Redes neurais artificiais na previsão de séries temporais*. Dissertação de Mestrado. Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro: PUC/DEE, 1994.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). *Inventário fluviométrico de bacias hidrográficas*. Brasília: ANELL, 1997. URL: <http://www.aneel.gov.br>
- AKAIKE, H. A new look at the statistical model identification. *IEEE Transactions on Automatic Control*. Vol. AC-19, N. 6, december 1974. p. 716-723.
- AZEVEDO, L. G. T, FONTANE, D. G, e PORTO, R. L. Sistemas especialistas para calibração de um modelo chuva-vazão. IX Simpósio Brasileiro de Recursos Hídricos e V Simpósio Brasileiro de Hidráulica e Recursos Hídricos. *Anais*. ABRH: Rio de Janeiro, 10 a 14 de Novembro, 1991. Vol. 4. p. 316-336.
- BALLINI, R. *Redes neurais artificiais para previsão chuva-vazão*. Dissertação de Mestrado. São Carlos: Instituto de Ciências Matemática de São Carlos/USP, 1996. 105pp.
- BALLINI, R. *Redes neurais multi-camadas e algoritmo back-propagation*. Campinas: s.e., 1997, 14pp. (xerog.).
- BAZARAA, M. S.; SHERALI, H. e SHETTY, C.M. *Nonlinear programming: theory and algorithms*. New York: John Wiley & Sons, 2 ed, 1993.

- BISHOP, C. M. *Neural networks for parttern recognition*. New York: Oxford University Press, 2<sup>a</sup> ed., 1997.
- BOX, G.E.P. e JENKINS, G. M. *Time series analysis forecasting and control*. Oakland: Holden-Day, 1976.
- BRAGA, P. F. B. Técnicas de otimização e simulação aplicadas em sistemas de recursos hídricos. In: BARTH, F. T. et al. *Modelos para gerenciamento de recursos hídricos*. São Paulo: Nobel/ABRH, 1987.p. 427-518.
- CASTRO, L. N. e Von Zuben, F. J. Optimization training techniques for feedfoward neural network. **Technical Report DCA-RT 03/98**. Campinas: UNICAMP/FEEC/DCA, July, 1998.
- CAUDILL, M e BUTLER, C. *Naturally intelligent systems*. Cambridge: MIT Press. 1990.
- CIRILO, J. A. Programação não linear aplicada a recursos hídricos. In: PORTO, R. L. L. (org.) *Técnicas quantitativas para o gerenciamento de recursos hídricos*. Porto Alegre: Ed. Universidade/UFRGS/Associação Brasileira de Recursos Hídricos, 1997.
- CLAIR, T. A. e EHRMAN, J. M. Using neural networks to assess the influence of changing seasonal climates in modifying discharges, dissolved organic carbon, and nitrogen export in eastern Canadian rivers. *Water Resources Research*. Vol.34, N.3, March, 1998. p.447-455.
- DECK, S. et al. Comparison of a neural network and traditional classifier for machine vision inspection. *Applied Engineering in Agriculture*.. Vol. 11, N. 2, 1995. p. 319-326.
- DOOGE, J. C. I. Linear theory of hydrology systems. *ARS*. Technical Bulletin, N. 1468, 1972.
- DOOGE, J. C. I. General reportan model structure and classification. In: ASKEW, A.J., GRACO, F. e KINDLER, J. (eds). *Logistics and benefits of using mathematical models of hydrologic and water resources systems*. IIASA Proceeding Series, vol 13, 1981. p.1-21.
- FOUNDATION FOR NEURAL NETWORKS'S (SNN). 1998. URL: <http://www.mbfys.kun.nl/snn/pointers/groups.html>
- FRIEDLANDER, A. *Elementos de programação não-linear*. Campinas: Editora da UNICAMP, 1994.

- 
- FUNDAÇÃO CENTRO TECNOLÓGICO DE HIDRÁULICA (FCTH)a. *Banco de dados pluviométricos do estado de São Paulo (atualizados até 1997)*. São Paulo:FCTH/DAEE/USP, v.1, 1997. CD-ROM.
- FUNDAÇÃO CENTRO TECNOLÓGICO DE HIDRÁULICA (FCTH)b. *Banco de dados fluviométricos do estado de São Paulo (atualizados até 1997)*. São Paulo:FCTH/DAEE/USP, v.1, 1997. CD-ROM.
- GROSSBERG, S. How does a brain build a cognitive code? *Psychological Review*. N. 87, 1980. p. 1-51.
- HAYKIN, S. *Neural network - A comprehensive foundation*. New York: McMillan College Company, 1994.
- HILLIER, F. S. e LIBERMAN, G. J. *Introduction to operations research*. New York: McGraw-Hill, 6ª ed, 1995.
- JORDAN, M.I. *Why the logistic function? A tutorial discussion on probabilities and neural networks*. 1995. URL: <ftp://psyche.mit.edu/pub/jordan/uai.ps.Z>.
- KAN, A. H. G. e TIMMER, G. T. Global Optimization. In: NEMHAUSER, G.L., KAN, A.H.G. (org.) *Handbooks in operations research and management science: Optimization*. Amsterdam: Elsevier, vol. 1, cap. 9, 1989. p.631-661.
- KOVÁCS, Z. L. *Redes neurais artificiais: fundamentos e aplicações*. São Paulo: Edição Acadêmica, 2ª ed.,1996.
- KULIGOWSKI, R. J. e BARROS, A. P. Using artificial neural network to estimate missing rainfall data. *Journal of the American Water Resources Association*. Vol34, N. 6, December, 1998. p. 1437-1447.
- LEONDES, C. T. *Algorithms and architectures*. San Diego: Academic Press, vol. 1. 1998.
- LOPES, J. E. G. e PORTO, R. L. *Modelo de Simulação Chuva - Vazão - SMAP*, v.96. Programa de Calibração,1996.
- LOPES, J. E. G. e PORTO, R. L. Técnica de pesquisa global de parâmetros para a calibração de modelos chuva-vazão. IX Simpósio Brasileiro de Recursos Hídricos e V Simpósio Brasileiro

- de Hidráulica e Recursos Hídricos. *Anais*. ABRH: Rio de Janeiro, 10 a 14 de Novembro, 1991. Vol. 4. p. 305-315
- LOPES, J. E. G., BRAGA, B. P. F. e CONEJO, J. G. L. In: *Curso de Engenharia hidrológica: Hidrologia dinâmica*. São Paulo: EPUSP/DAEE/ABRH, v.1, 2v. 1983.
- MATHWORKS. *Neural Network Toolbox User's Guide - For use with MATLAB v.3*. Mass.:The MathWoks, Inc.1998.
- McCULLOCH, E. S. e PITTS, W. A logical calculus of the ideas immament in neurons activity. *Bulletins of Mathematical Biophysics*. Vol.5, 1943. p. 115-133.
- MINSKY, M. L., e PAPERT, S. A. *Perceptrons: na introduction to computacional geometry*. Cambridge Mass.: MIT Press, 1969.
- MOLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*. N. 6, 1993. p. 525-533.
- MORETTIN, P. A. e TOLOI, C. M C. *Previsão de séries temporais*. São Paulo: Atual Ed. Ltda, 1985.
- NEURAL NETWORKS RESEARCH (NNR). IEEE Neural Network Council's. URL: <http://www.ieee.org/nnc>.
- NIGRINI, A. *Neural networks for pattern recognition*. Cambridge, MA: The MIT Press, 1993.
- NOVAES, G. N. *Métodos de otimização: aplicações aos transportes*. São Paulo: Edgar Blücher, 1978.
- OSSENBRUGGEN, P. J. *Fundamental principles of systems analysis and decision-makeng*. New York: John Willey & Sons, Inc., 1994.
- PARMA, G. G. , MENEZES, B. R. e BRAGA, A. P. Aprendizado on-line da RNAs multicamadas baseado na teoria de sistemas de estrutura variável. *Anais*. IV Simpósio de redes Neurais. Goiânia: Ed. UFG, 3-5 de dezembro, 1997. p-80-82.
- PRECHELZ, L. Automatic early stopping using cross validation: quantifying the criteria. *Neural Networks*. Vol. 11, N. 4, 1998. p. 761-769.
- ROJAS, R. *Neural networks: a systematic indroduction*. Berlin: Springer, 1996.

- 
- ROMERO, R. A. F. *Otimização de sistemas através de redes neurais artificiais*. Tese de doutorado. Faculdade de Engenharia Elétrica:DECAI/Unicamp,1998.
- ROSENBROCK, H.H. An automatic for finding the greatest or least value of a fuction. *Computer Journal*. Vol 3, 1960. p. 175-184.
- RUMELHART, D. E., McCLEALAND, J. L. and the PDP Research Group (Eds.). *Parallel distributed processing: Explorations in the microstructure of cognition*, vol. 1: Foundions. Cambridge, MA: MIT Press, 1986.
- RUMELHART, W. S., HINTON, G. E. e WILLIAMS, R. J. Learning internal, representations by error propagation. In: RUMELHART, D. E., McCLEALAND, J. L. and the PDP Research Group (Eds.). *Parallel distributed processing: Explorations in the microstructure of cognition*, vol. 1: Foundions. Cambridge, MA: MIT Press, 1986. p. 318-362.
- SANTOS, V. P. e ROMERO, R. A. F. Utilização do Matlab para o desenvolvimento de redes neurais. *Relatórios Técnicos*, nº 18. Intitulo de Ciências Matemáticas de São Carlos. USP.1994.
- SARLE, W. S. Sttoped training and other remedies for overfitting. *Proceedings of the Simposium na the Interface*. 1995. URL: <ftp://ftp.sas.com/pub/neural/inter96.ps.Z>
- SCHWARZ, G. Estimating the dimension of a model. *The Annals of Statistics*. Vol. 6, N. 2, 1978. p. 461-464.
- SILVA, L. N. C. *Análise e síntese de estratégias de aprendizado para redes neurais artificiais*. Dissertação de Mestrado. Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas. Campinas: FEE/DECAI, 1998.
- SOROOSHIAN, S. GUPTA, V. K. e FULTON, J. L. Evaluation of maximum likelihood parameter estimation techniques for conceptual rainfall-runoff models - Influence os calibration data variability and length on model credibility. *Water Resources Research*. 19(1), 1983. p. 251-259.
- TAO, Y. et al. Machine vision for color inspection of potatoes and apples. *Transactions of the American Society of Agricultural Engineers*. Vol 38, N. 5, 1995. p. 1555-1561.

- 
- TAWEL, R.; MARKO, K., e FELDKAMP, L. *Custom VLSI ASIC for automotive applications with recurrent networks*. 1998. URL: <http://www.jpl.nasa.gov/releases/98/ijcnn98.pdf>
- THOMAZ, F. R., MAGALHÃES, P. C. e XAVIER, A. E. Alguns aspectos da calibração automática de modelos chuva-vazão. IX Simpósio Brasileiro de Recursos Hídricos e V Simpósio Brasileiro de Hidráulica e Recursos Hídricos. *Anais*. ABRH: Rio de Janeiro, 10 a 14 de Novembro, 1991. Vol. 4. p. 295-304.
- TRIPPI, R.R. e TURBAN, E. *Neural networks in finance and investing*. Chicago: Probus, 1993.
- TUCCI, C. E. M et al (org). *Hidrologia: ciência e aplicação*. Porto Alegre: Ed. Da Universidade/EDUSP/ABRH, 1993.
- TUCCI, C. E. M Modelos determinísticos. In: BARTH, F. T. et al. *Modelos para gerenciamento de recursos hídricos*. São Paulo: Nobel/ABRH, 1980. p. 211-323.
- TUCCI, C. E. M., PORTO, R. L. e BARROS, M. T. (orgs.). *Drenagem urbana*. Porto Alegre: ABRH/Editora da Universidade/URGS, 1995.
- VINCKE, P.; GASSNER, M. e ROY, B. *Multicriteria decision-aid*. New York: John Wiley & Sons, 1992.
- VON ZUBEN, F. J. *Notas de Aula*. 1999. URL: <http://www.dac.fee.unicamp/~vonzuben/vonzuben.html>
- VON ZUBEN, Fernando José. *Modelos paramétricos e não-paramétrico de redes neurais artificiais e aplicações*. Tese de Doutorado. Faculdade de Engenharia Elétrica da Universidade Estadual de Campinas. Campinas: FEE/DECAI, 1996.
- WALLEY, W. J. e FONTANA, V. N. Neural network predictors of average score per taxon and number of families at unpolluted river sites in Great Britain. *Water Resources Research*. Vol.34, N.3, March, 1998. p.427-436. Vol.32, N.3, 1998. p. 613-622.
- WASSERMAN, P. D. *Neural computing - theory and practice*. New York: VNR, 1989.
- WEN, C. e LEE, C. A neural approach to multiobjective optimization for water quality management in a river basin. *Water Resources Research*. Vol.34, N.3, March, 1998. p.427-436.

---

WIDROW, B e HOFF Jr, M.E. Adaptive switching circuits. *IRE WESCON Convention Record*, Part 4, 1960. p. 96-104.

WIDROW, B. Generalization and information storage in networks of adaline 'neurons'. In: YOVITZ, M.C, JACOBI, G.T. e GOLDSTEIN, G.D. eds. *Self-organizing systems*. Washington D.C.: Sparta, 1962. p. 435-461.

ZURADA, J. M. *Introduction to artificial neural systems*. Boston: Plus Publishing Company, 1992.

## BIBLIOGRAFIAS CONSULTADAS

- AMARAL, M. F. O modelo SSARR. In: **Curso de Engenharia Hidrológica**. Hidrologia Dinâmica, v.1. São Paulo: EPUSP/DAEE/ABRH, 1983, 2v., p. E1-16.
- ANDERSON, M.G. e BURT, T.P. *Hydrological forecasting*. Great Britain: John Wiley & Sons Ltd, 1990.
- ANDRADE FILHO, A. G. e CHAUDHRY, F. H. Previsão chuva-vazão pelo método de vizinhos mais próximos. *Anais*. XI Simpósio Brasileiro de Recursos Hídricos e II Simpósio de Hidráulica e Recursos Hídricos dos Países de Língua Oficial Portuguesa. Recife: ABRH, vol. 1, 1995. p. 69-74.
- BAPTISTA, M. B., MICHEL, C. e PINHEIRO, M. C. Proposição de um modelo simplificado global de propagação de cheias - aplicação em cursos de água do sul e sudeste do Brasil. *Anais*. I Simpósio de Recursos Hídricos do Nordeste. Recife: ABRH, 1992. p. 356-366.
- BARTOLINI, P. B. e VALDÉS, J. B. Representation of spatial variability of rainfall in aggregated rainfall-runoff models. *Journal of Hydraulic Engineering*. Vol. 120. N.10, 1993. p. 1199-1219.

- BARTOLINI, P. e VALDES, J. B. Representation of spatial variability of rainfall in aggregated rainfall-runoff models. *Journal of Hydraulic Engineering*. Vol. 120, N. 10, October, 1994, p. 1199-1219.
- BRAGA JR, B. P. F. e CONEJO, J. G. L.. Simulação digital do ciclo hidrológico através do "stanford watershed model IV". In: *Curso de Engenharia Hidrológica*. Hidrologia Dinâmica, v.1. São Paulo: EPUSP/DAEE/ABRH, 1983, 2v., p. B1-114.
- CALDER, I. R. et al. The impact of use change on water resources in sub-Saharan African: a modelling study of Lake Malawi. *Journal of Hydrology*. 170, 1995. p. 123-135.
- CANEDO, P. M., SILVA, L. P. e XAVIER, A. E. Calibração automática de modelos chuva-vazão por meio de técnicas de suavização. *Anais*. Lisboa: IV Simpósio Luso Brasileiro de Hidráulica e Recursos Hídricos. V.2, 1989. p.277-287.
- CHANG, L. H., HUNSAKER, C. T. e DRAVES, J. D. Recent research on effects of climate change on water resources. *Water Resources Bulletin*. v.28, nº 2, p.273-286, April, 1992.
- CIRILO, J. A. e LUCENA, J. H. Modelos de simulação hidrológica aplicada a bacias hidrográficas do estado de Pernambuco. *Anais*. I Simpósio de Recursos Hídricos do Nordeste. ABRH: Recife, 25 a 27 de Novembro, 1992. Vol. 2. p. 211-222.
- COELHO, F. S. A. *Análise e avaliação do hidrograma unitário geomorfológico e geomorfoclimático para pequenas bacias rurais*. Dissertação de mestrado. Faculdade de Engenharia Civil : DRH/Unicamp, 1998.
- DELLEUR, J. W., TAO, P. C. e KAVVAS, M. L. Na evaluation of the practicality and complexity of some rainfall and runoff time series models. *Water Resources Research*. 12(5), 1976. p. 953-970.
- DUAN, Q. E. , SOROOSHIAN, S. e GUPTA, V. K. Effective and efficient global optimization for conceptual rainfall-runoff models. *Water Resources Research*. Vol. 28, N. 4, 1992. p. 1015-1031.
- DUAN, Q. E. , SOROOSHIAN, S. e GUPTA, V.K. Optimal use of the SCE-UA global optimization method for calibrating watershed models. *Journal of Hydrology*. 158, 1994. p.265-284.
- DUCHON, C. E. et al. An example of using Landsat and GOES data in a water budget model. *Water Resources Research*. Vol. 28, N. 2, 1992. p. 527-538.

- ELTAHIR, E. A. B. e BRAS, R.L. Sensitivity of regional climate to deforestation in the amazon basin. *Advances in Water Resources*. N. 17, 1994. p.101-115.
- FAO (Food and Agriculture Organization of the United Nations). Mans's influence na the hydrological cycle. *Irrigation and Drainager Paper*. Rome: FAO, 1973.
- FERNANDES, D. et al. (a). *Inventário das estações pluviométricas*. Brasília: DANEE (Departamento Nacional de Águas e Energia Elétrica), 1996.
- FERNANDES, D. et al. (b). *Inventário das estações pluviométricas*. Brasília: DANEE (Departamento Nacional de Águas e Energia Elétrica), 1996.
- FIGUEIREDO, E. E., OVERLAND, H. e KLEEBERG, H. B. O modelo NAVMO de simulação superficial. *Anais. I Simpósio de Recursos Hídricos do Nordeste*. Recife: ABRH, 1992. p. 337-345.
- GAN, T. Y. e BURGESS, S. J. (a) An assessment of a conceptual rainfall-runoff model's ability to represent the dynamics of small hypothetical catchments: 1. Model, properties, and experimental design. *Water Resources Research*. Vol. 26, N. 7, 1990. p. 1595-1604.
- GUPTA, K. V. , SOROOSHIAN, S. e YAPO, P. Towards improved calibration of hydrologic models: multiple and non-commensurable measures of information. *Water Resources Research*. Vol. 34, N. 4, 1998. p. 751-763.
- GUPTA, V. K. e SOROOSHIAN, S. (a) Uniqueness and observability of conceptual rainfall-runoff model parameters: The percolation process examined. *Water Resources Research*. Vol. 21, N. 4, 1985. p. 473-486.
- GUPTA, V. K. e SOROOSHIAN, S. (b) The relationship between data and the precision of estimated parameters. *Journal of Hydrology*. N. 81, 1985. p. 57-77.
- GUPTA, V. K. e SOROOSHIAN, S.(c) The automatic of conceptual catchment models using derivative-based optimization algorithms. *Water Resources Research*. Vol. 21, N. 4, 1985. p. 473-485.
- HANSEN, J. e NELSON, R. D. Neural network and traditional time series methods: A synergistic combination in state economic forecasts. *IEEE Transactions on Neural Networks*. Vol. 8, N. 4, July 1997. p. 863-873.

- HENDRICKSON, J. D. e SOROOSHIAN, S. Comparison of Newton-type and direct search algorithms for calibration of conceptual rainfall-runoff models. *Water Resources Research*. Vol. 24, N. 5, 1998. p. 691-700.
- HERMANN, R. M. (a). *Modelos de simulação no planejamento de recursos hídricos*. Notas de aula. São Paulo: EPUSP/DEH, 1980.
- HERMANN, R. M. (b). *Simulação hidrológica*. São Paulo: EPUSP/DH, 1980. Notas de aula, PHD - 718 - Sistemas de Recursos Hídricos II.
- HILL, T.; O'CONNOR, M.; REMUS, W. Neural Networks Models for Time Series Forecasts. *Management Science*, Vol.42, N. 7, July 1996. p. 1082-1092.
- HOSKING, J. R. M e CLAKE, R. T. Rainfall-runoff relations derived from the probability theory of storage. *Water Resources Research*. Vol. 26, N. 7, 1990. p. 1455-1463.
- HSU, K., GUPTA, K. V. e SOROOSHIAN, S. Artificial neural network modeling of the rainfall-runoff process. *Water Resources Research*. Vol. 31, N. 10, 1995. p. 2517-2530.
- HUGHAS, D. A. Soil moisture and runoff simulations using four catchment rainfall-runoff models. *Journal of Hydrology*. 158, 1994. p. 381-404.
- IDSO, S.B. e BRAZEL, A.J. Rising atmospheric carbon dioxide concentrations may increase streamflow. *Nature*. N. 312, 1984. p.51-53.
- JAMES, W. P. et al. Radar-assisted real-time flood forecasting. *Journal Water Resources Planning e Manegment*. Vol. 119, N. 1, 1993. p. 32-44.
- KITANIDIS, P. K. e BRAS, R. L.(a) Real-time forecasting with a conceptual hydrologic model: Analysis of uncertainty. *Water Resources Research*. Vol. 16, N. 6, 1980. p. 1025-1033.
- KITE, G. W. Aplicação de um modelo hidrológico de classes de solo para mudanças climáticas. *Water Resources Research*. Vol. 29, N. 10, , July 1993. p. 2377-2384.
- KITE, G.W. e WAITITU, J.K. Effects of changing precipitation and evaporation on nazoia river flow and lake victoria levels, contribution to world climate program. *Report*. Genève: World Metereolog. Org., 1981.
- KUCHMENT, L. S. et al. Rainfall-runoff modelling of Ouse basin, North Yorkshire: an application of a physically based distributed model. *Journal of Hydrology*. N. 181, 1996. p. 323-342.

- KUCHMENT, L.S., DEMIDOV, V.N., COOPER, D.M. e BROADHURST, P. Rainfall-runoff modelling of the Ouse basin, North Yorkshire: in application of a physically based distributed model. *Journal of Hydrology*. N. 181, 1996, p. 323-342.
- KUCZERA, C. Improved parameter inference in catchment models, 1 - evaluating parameter uncertainty. *Water Resources Research*. Vol.19, N. 5, 1983. p.1151-1162.
- LAU, C. G. Neural networks, I: theory and modeling. *Proceedings of the IEEE*. Vol. 78, N. 9, september 1990, p. 1411-1414.
- LEE, Y. S., OH, S. e KIM, M. The effect os initial weights on premature saturation in back-propagation learning. *International Joint Conference on Neural Networks*. Vol. 1, Seattle, WA, 1991. p. 765-770.
- LEITE, F. E. A. *Aplicação de redes neurais artificiais na previsão de curto prazo da carga nodal de sistemas de energia elétrica*. Dissertação de Mestrado. Campinas: Faculdade de Engenharia Elétrica e de Computação/UNICAMP, 1997.
- LIMA, W. S. *Previsão de carga no período de demanda de ponta utilizando redes neurais artificiais*. Dissertação de Mestrado. Faculdade de Engenharia Elétrica da Universidade Federal de Campinas. Campinas: FEE/DES, 1996.
- LIPPMANN, R. P. An introduction to computing with neural nets. *IEEE ASSP Magazine*. Vol.4, N. 2, April, 1987, p. 4-22.
- LOPES, J. E. G, BRAGA, B. P. F. e CONEJO, J. G. L. Simulação hidrológica: aplicação de um modelo simplificado. IV Simpósio Brasileiro de Hidrologia e Recursos Hídricos. *Anais*. ABRH: Fortaleza, 15 a 19 de Novembro, 1981. Vol.2. p.42-48.
- LUENBERGER, D. G. *Linear and nonlinear programming*. Massachusetts: Addison-Wesley Publishing Company, 2<sup>a</sup>. ed, Cap. 6, 1973. p. 167-196.
- MAIA NETO, R. F. e LOPES, E. S. Monitoramento hidrológico da bacia amazônica. V Simpósio Luso Brasileiro de Hidráulica e Recursos Hídricos, IX Simpósio Brasileiro de Recursos Hídricos. *Anais*. Rio de Janeiro, 10 a 14 de novembro, 1991. Vol. Recursos Hídricos e Meio Ambiente, p. 40-49.
- MASON, J. C., PRINCE, R. K. e TEMME, A. A neural network model of rainfall-runoff using radial basis functions. *Journal of Hydraulic Research*. Vol. 34, N. 4, 1996. p. 537-548.

- MATHWORKS. *MATLAB User's Guide - High-performance numeric computataion and visualization software*. Mass.:The MathWoks, Inc, 1998.
- MAYS, L. W. *Water resources handbook*. New York: McGraw-Hill, 1996.
- MILLER, J. R. e RUSSEL, G. J. The impact of global warming on river runoff. *Journal of Geophysical Research*. Vol 97, N. D3, Febr. 1992. p.2757-2764.
- NEMEC, J. e SCHAAKE, J. Sensitivity os water resources systems to climate variation. *Hydrology Sciences Journal*. Vol. 27, N. 3, 1982. p. 327-343.
- NEMHAUSER, G.L., KAN, A.H.G., TODD, M. J. *Handbooks in operations research and management science*. Amsterdam: Elsevier, vol. 1, 1989.
- NIKOLAIDS, N. P. et. al. Hydrology response of freshwater watersheds to climatic variability: model development. *Water Resources Research*. Vol. 29. N. 10, October 1993. p.3317-3328.
- PERIN FILHO, Clovis. *Introdução à simulação de sistemas*. Campinas, SP: Editora da UNICAMP, 1995.
- PONCE, V. M. e SHETTY, A. V. (a) A conceptual model of catchment water balance: 1. Formulation and calibration. *Journal of Hydrology*. N. 173, 1995. p. 27-40.
- PONCE, V. M. e SHETTY, A. V. (b) A conceptual model of catchment water balance: 2. Application to runoff and baseflow modeling. *Journal of Hydrology*. Vol. 173, 1995. p. 41-50.
- RAMOS, F. et al. *Engenharia hidrológica*. Rio de Janeiro: ABRH, editora da UFRJ, 1989.
- RITZI, R. W., SOROOSHIAN, S. e GUPTA, V. K. On the estimation of paramters for frequency domain models. *Water Resources Research*. Vol. 27, N. 5, 1991. p. 873-882.
- SALATI, E. e MARQUES, J. Climatology os the amazon region. *The amazon, limnnology and lanscape ecology of a mighty tropical ricer and its basin*. Netherlands: ed. Sioh H., 1984. p. 85-126.
- SALATI, E. e NOBRE, C. A. Possible climatic impacts of tropical deflorestation. *Climatic Changes*. April, 1990.
- SARMENTO, F. J. Modelagem de séries hidrológicas através de redes de neurônios. *Revista Brasileira de Recursos Hídricos*. Vol.1, N. 2, Jul./Dez, 1996. p.19-31.

- SCHENCK Jr, H. *Theories of engineering experimentation: planning, execution, reporting*. McGraw Hill Int. Edtions, 1995.
- SEHITOGLU, H. Some algorithms for parameter estimation in water resources systems. *Water Resources Research*. Vol. 19, N. 5, 1983. p. 1193-1202.
- SHAMSELDIN, A. Application of reural network technique to rainfall-runoff modelling. *Journal of Hydrology*. N. 199, 1997. p. 272-294.
- SHIMIZU, T. *Simulação em computador digital*. São Paulo: Edgard Blücher Ltda, 1975.
- SHUTTLEWORTH, J. W. et al. Post-deforestation amazonian climate: anglo-brasilian research to improve prediction. In: *Water management of the amazonian basin*. ed. Braga, Jr and Ferdandez-Jáuregui,, 1991. p. 275-288
- SILVA, M. J. D. e PORTO, R. L. Análise de efeitos da alteração do uso do solo através de modelo matemático de chuva-vazão. *Anais*. I Simpósio de Recursos Hídricos do Nordeste. Recife: ABRH, 1992. p. 527-535.
- SINGH, V. P. *Hydrologic syistems - rainfall-runoff modelling*. Englewood Cliffs: Prentice-Hall, 1988.
- SINGH, V.P. *Computer models af watershed hydrology*. Highlands Ranch: Water Resources Publications, 1995.
- SMITH, J. e ELI, R. N. Neural-network models of rainfall-runoff process. *Journal of Water Resources Planning and Management*. November/December, 1995. p. 499-508.
- SOROOSHIAN, S. e GUPTA, V. K. Automatic calibration of conceptual rainfall-runoff models: The quastion of parameter oservability and uniqueness. *Water Resources Research*. 19(1), 1983. p. 251-259.
- SOROOSHIAN, S. e GUPTA, V. K. The analysis of structural identifiability theory and application to conceptual rainfall-runoff models. *Water Resources Research*. Vol. 21, N. 4, 1985. p. 487-496.
- SOROOSHIAN, S., DUAN, Q. e GUPTA, V. K. Calibration of rainfall-runoff models: Application of global optimization to the Sacramento soil moisture accounting model. *Water Resources Research*. Vol 19, N. 4, 1993. p. 1185-1194.
- SOUZA, M. S., MACHADO, D. e MARTINO, M. B. Determinação de vazões utilizando redes neurais. *Anais*. XI Simpósio Brasileiro de Recursos Hídricos e II Simpósio de Hidráulica e

- Recursos Hídricos dos Países de Língua Oficial Portuguesa. Vol. 1. Recife, Nov.1995. p. 63-68.
- SOUZA, M.S., MACHADO, D., MARTINO, M.B. Determinação de Vazões Utilizando Redes Neurais. *Anais*. XI Simpósio Brasileiro de Recursos Hídricos, Vol.1, Recife, PE, Nov. 1995. p.63-68.
- SRINIVASAN, V. S. e GALVÃO, V. O. Modelagem por evento do escoamento superficial para as micro-bacias de uma região semi-árida da Paraíba. *Anais*. I Simpósio de Recursos Hídricos do Nordeste. Recife: ABRH, 1992. p. 347-355.
- TANG, Z., ALMEIDA, C. e FISHWICK, P. A. Times series forecasting using neural networks vs. Box-Jenkins. *Simulation*. Vol. 57, N. 5, Nov. 1991. p. 303-310.
- TODINI, E. The ARNO rainfall-runoff model. *Journal of Hydrology*. N. 175, 1996. p. 339-382.
- TOMASELLA, J. , OYAMA, M. D. e HODNETT, M. G. Validação de um modelo simples de água no solo para um sítio da Amazônia Central. *Anais*. XI Simpósio Brasileiro de Recursos Hídricos e II Simpósio de Hidráulica e Recursos Hídricos dos Países de Língua Oficial Portuguesa. Recife: ABRH, vol. 1, 1995. p. 111-115.
- TROENDLE, C.A. Global change: can we detect its effect on subalpine hydrography. In: *Proceedings 59th Western Snow Conference*. Colorado University, Fort Collins, 1991. p. 1-7.
- TSUANG, B.J., e DRACUP, J.A. Effect of global warming on sierra nevada mountains snow storage. In: *Proceedings 59th Western Snow Conference*. Colorado University, Fort Collins, 1991. p. 1-7.
- TUCCI, C. E. M. *Modelos hidrológicos*. Porto Alegre: ed. Universidade/UFRGS/Associação Brasileira de Recursos Hídricos, 1998.
- USUNOFF, E., CARRERA, J. e MOUSAVI, S. F. Na approach to the design of experiments for discrimination among alternative conceptual models. *Advances in Water Resources*. 15, 1992. p. 199-214.
- WALLEY, W. J. e FONTANA, V. N. Neural network prediction of average sacore per taxon and number of families at unpolluted rever sites in Great Britain. *Water Resources Research*. Vol. 32. N. 3, 1998. p. 613-622.

- 
- WIDROW, Bernard e LEHR, Michael A. 30-year of adaptive neural networks: perceptrons, madaline, and backpropagation. *Proceeding of IEEE*. Vol. 78, N. 9, september 1990, p. 1415-1441.
- YAPO, P. O., GUPTA, K. V. e SOROOSHIAN, S. Multi-objective global optimization for hydrologic models. *Journal of Hydrology*. N. 204, 1998, p. 83-97.
- YAPO, P. O., GUPTA, H. V. e SOROOSHIAN, S. Automatic calibration of conceptual rainfall-runoff models: sensitivity to calibration data. *Journal of Hydrology*. N. 181, 1996. p. 23-48.

## Abstract

Barp, Ana Rosa Baganha. *Rainfall-runoff Modelling in the Hydrographics Basin with Suport of the Artificial Neural Network*. Campinas, Faculdade de Engenharia Civil, Universidade Estadual de Campinas, 1999. 259 p. Tese (Doutorado)

This work describes the use of two hydrological simulation deterministic models to represent the rainfall-runoff process. The Itapetiniga, Almas and Guarapiranga rivers basin, located in the State of São Paulo and the Guaporé river basin located in the State of Mato Grasso, are taken as a case study. Both deterministic models used parameters optimization, with a non-linear and unconstrained structure: (a) SMAP – Soil Moisture Accounting Procedure, which uses a first order optimization procedure; (b) Artificial Neural Network (ARN) model, which uses a second order optimization procedure. Both models assume a montly interval to account rainfall and river flow. Some tests include a mix structure between SMAP and ARN, aiming at an evaluation of ARN potential to replace physical parameters and typical processes of conceptual rainfall-runoff models.

**Key-Words:** Rainfall-runoff Models, Hydrologic Simulation, Artificial Neural Network, Otimization

---

## Apêndice A - Algoritmo Backpropagation

O algoritmo *Backpropagation* (BP), ou da retropropagação do erro, é empregado em uma MLP com topologia do tipo não-recorrente<sup>1</sup>, a qual se apresenta, geralmente, com três camadas (entrada, escondida e saída), heteroassociativo<sup>2</sup>, com conexões de alimentação direta da camada de entrada para a camada escondida e desta para a camada de saída.

O objetivo do algoritmo é ajustar os pesos através da minimização do erro obtido na saída da rede decorrido do aprendizado do vetor de treinamento (vetor de entrada e vetor meta desejado) (WASSERMAN, 1989).

Seja uma RNA Multicamadas  $m$  representada por (Figura A.1):

---

<sup>1</sup> São RNA que não possuem realimentação de suas saídas para as suas entradas e por isso são ditas “sem memória”.

<sup>2</sup> A natureza dos padrões de entrada e saída são diferentes.

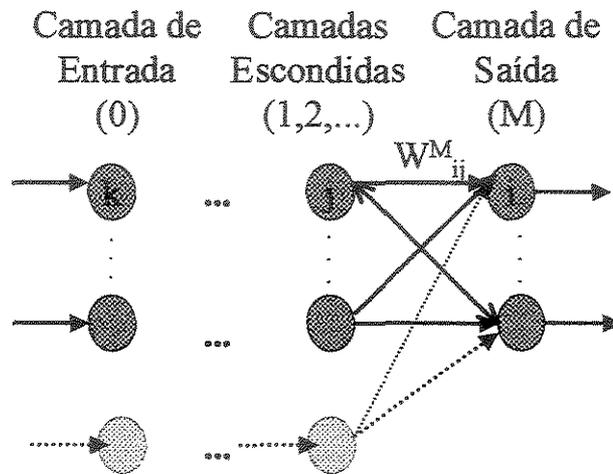


Figura A.1 - RNA com m Camadas

Para a operacionalização do algoritmo BP é necessário seguir uma rotina de cálculo, a qual é dividida em dois sentidos, uma que chamaremos de *seqüência progressiva* em que o sentido de cálculo é para frente e a outra de *seqüência regressiva* que calcula a rede no seu sentido contrário.

1. **Seqüência Progressiva (Forward)**

Os pesos sinápticos não são alterados e o cálculo é iniciado na primeira camada escondida, com a apresentação do vetor de entrada e termina na camada de saída com o cálculo do vetor erro para cada neurônio desta camada. A seqüência se resume em:

- *Passo 1:* Deve-se inicializar a rede aplicando valores aleatórios pequenos aos pesos sinápticos  $W$ ; e níveis de limiares  $\theta$ ,
- *Passo 2:* Dentre os padrões de treinamento existentes, escolhe-se um par  $(p_k, d_k)$  e aplica-se à camada de entrada (0), sendo

$$A_k^0 = p_k^p, \forall k \tag{A.1}$$

- *Passo 3:* Ao longo da rede o sinal deve ser progressivamente propagado aplicando

$$A_i^m = \varphi(n_i^m) = \varphi\left(\sum_j w_{ij}^m \times A_j^{m-1}\right) \tag{A.2}$$

para cada valor de  $i$  e até que a saída  $A_i^M$  seja calculada.

## 2. Sequência Regressiva (Backward)

Inicia na camada de saída da rede e corrige os novos pesos sinápticos através da retropropagação do erro calculado para cada neurônio referente as camadas subsequentes da rede e, resume-se em:

- *Passo 4:* Calcula-se os valores de delta  $\delta$  correspondentes a cada camada.

Se for a camada de saída será por

$$\delta_i^M = \varphi'(n_i^M) [a_i^p - A_i^M] \quad (\text{A.3})$$

Se forem as camadas escondidas será avaliado por

$$\delta_i^{m-1} = \varphi'(n_i^{m-1}) \sum_j w_{ji}^m \cdot \delta_j^m \quad (\text{A.4})$$

- *Passo 5:* Para se corrigir os pesos, ou seja, calcular os novos valores pesos, aplicam-se as expressões

$$\Delta_{ij}^m = \eta \cdot \delta_i^m \cdot A_j^{m-1} \quad (\text{A.5})$$

$$w_{ij}^{novo} = w_{ij}^{velho} + \Delta_{ij} \quad (\text{A.6})$$

- *Passo 6:* Retorne ao *Passo 2* e repita o procedimento para o próximo padrão.

A rede então finalizará o cálculo após todos os padrões terem sido apresentados e atendido segundo o(s) critério(s) de parada, previamente estabelecidos.

Este algoritmo, apesar de sua enorme aplicação e popularidade, apresenta alguns problemas, tais como: