

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE PESQUISAS HIDRÁULICAS**

**ANÁLISE DA OPERAÇÃO DE SISTEMAS DE RESERVATÓRIOS UTILIZANDO
LÓGICA DIFUSA, REDES NEURAS ARTIFICIAIS E SISTEMAS NEURO-DIFUSOS**

Henrique Vieira Costa Lima

Tese submetida ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul como requisito parcial para a obtenção do título de Doutor em Recursos Hídricos e Saneamento Ambiental.

Orientador: Prof. PhD. Antônio Eduardo Leão Lanna

Co-orientador: Prof. DR. Olavo Pedrollo

BANCA EXAMINADORA

Prof. DR. Carlos de Oliveira Galvão – UFCG

Prof. DR. João Soares Viegas Filho – UFPEL

Prof. DR. André Silveira – IPH/UFRGS

Prof. DR. Carlos André Bulhões Mendes – IPH/UFRGS

Porto Alegre, Junho de 2006.

*Dedico este trabalho a minha esposa
Luciana e a minha filha Letícia, razões de
minha existência.*

APRESENTAÇÃO

Este trabalho foi desenvolvido no Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental do Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul, sob orientação dos professores Antônio Eduardo Lanna (orientador) e Olavo Correa Pedrollo (co-orientador), ambos da Universidade Federal do Rio Grande do Sul.

Desejo nesta apresentação agradecer a todas as instituições, em especial ao Instituto de Pesquisas Hidráulicas/UFRGS (por me dar a honra de ser seu aluno), e a Concremat Engenharia e Tecnologia S/A (pelo apoio e por liberar-me de minhas funções para desenvolver esta pesquisa) e todas as pessoas que direta ou indiretamente contribuíram para a conclusão desta tese.

Agradeço, em especial, sujeito sempre a esquecimentos, aquelas pessoas que participaram de forma direta do processo da minha formação, seja no campo pessoal, acadêmico e/ou profissional:

- ✓ Ao professor Eduardo Lanna, pela confiança e pela oportunidade de ser novamente seu orientado;
- ✓ Ao professor Olavo Pedrollo, pela confiança, incentivo e por compartilhar comigo uma pequena parcela de seu enorme conhecimento técnico-científico;
- ✓ Ao professor Nilson Campos, por ser sempre meu “orientador”, desde os primeiros passos na pesquisa como seu bolsista de iniciação científica;
- ✓ Aos professores André Silveira, Carlos André Mendes, João Soares Viegas e Nilson Campos, pelas contribuições como membros de minha banca de exame de qualificação;
- ✓ Aos professores e funcionários do IPH, em especial Nadir Solari e Márcia Feijó, pelo apoio em todos os momentos;
- ✓ Aos diretores da Concremat, em especial Alain David, Antonio Delia, Celso Queiroz, Eduardo Miana e Mauro Filho, incentivadores de minha formação acadêmica;

- ✓ Aos amigos Gustavo Coelho, Joaquim Cartaxo, José de Ribamar Sousa e Luís Gustavo Reis, pelo apoio e incentivo, em especial durante os momentos mais difíceis desta caminhada;
- ✓ Aos amigos Alexandre Costa, Alfonso Rizzo, Assis Filho, Carlos Henrique Lima, Celecina Veras, Eduardo Sávio, Emanuel Melo, Fátima Bandeira, Lawson Beltrame, Maurício Bernardes, Mizael Ramos, Paulo Coelho, Roberto Smith, Ricardo Santiago, Sidnei Agra, Sinara Pereira, Valmir Pedrosa e Wilton Nascimento, que foram, de diferentes formas, indispensáveis nesta caminhada;
- ✓ Aos meus pais Pardaillan e Ana Maria, e irmãos Luiziana, Magno, Luciana e Rodrigo, por sempre acreditarem que sou capaz de fazer coisas que nem eu mesmo acredito;
- ✓ A duas pessoas muito especiais em minha vida: minha esposa Luciana, sem a qual nada faria ou faz sentido e minha filha Letícia, que mesmo sem saber, com sua alegria e carinho, me proporcionou forças para continuar acreditando.

RESUMO

O uso de modelos matemáticos na análise de sistemas de recursos hídricos tem se desenvolvido bastante desde a década de 1960. Uma das principais áreas de aplicação dos modelos de análise de sistemas de recursos hídricos é no planejamento e na operação de sistemas de reservatórios. Dois tipos de abordagem podem ser adotados para a solução desse tipo de problema: abordagem tradicional, baseada em técnicas de pesquisa operacional, e abordagem por sistemas inteligentes (inteligência artificial – IA). Modelos baseados em IA têm como principal característica a flexibilidade de inclusão de regras expressas em uma linguagem de fácil compreensão que incorporam na modelagem o conhecimento especializado e a experiência dos operadores. Apesar da importância do assunto e do potencial das técnicas, o estágio de desenvolvimento atual é carente de fundamentação teórica que sistematize a prática vivencial dos atores nos processos. Pesquisas que fechem essa lacuna são necessárias para que melhor se conheçam as vantagens e desvantagens dos Sistemas Inteligentes aplicados à operação de sistemas de reservatórios. Foram escolhidas para teste técnicas baseadas em lógica difusa, redes neurais artificiais e sistemas híbridos neuro-difusos. Investigar o potencial destas técnicas para o processo de tomada de decisão na operação de sistemas de reservatórios constitui o objetivo geral desta pesquisa. As definições e as implementações dos esquemas metodológicos propostos nesta pesquisa e suas aplicações no estudo de caso do sistema que abastece a região metropolitana de Fortaleza confirmaram a hipótese da pesquisa para duas das três técnicas avaliadas – os modelos baseados em lógica difusa e os modelos baseados em redes neurais artificiais. A terceira técnica testada – sistemas de inferência adaptativos neuro-difusos – apresentou resultados insatisfatórios. As principais contribuições desta pesquisa ao estado da arte estão principalmente nos seguintes pontos: definição de esquemas metodológicos utilizando abordagens baseadas em sistemas inteligentes na obtenção de políticas operacionais para sistemas de reservatórios em regiões semi-áridas; inclusão, nos sistemas inteligentes para obtenção de políticas operacionais, de variáveis semânticas (qualitativas) indicativas da previsão climática, avaliando tanto a melhora do processo de operação dos reservatórios quanto os erros potenciais decorrentes de previsões equivocadas; utilização, em conjunto, de técnicas de agrupamento e de aprendizado organizativo na construção de sistemas especialistas difusos para operação de sistemas de reservatórios; construção e utilização, para os sistemas especialistas difusos de operação de reservatórios, de *Modelos Hierarquicamente Escalonados*, evitando a “Falta de Conhecimento”.

ABSTRACT

The use of mathematical models in the analysis of water resources systems grew enough since the decade of 1960. One of the main areas of application of the models is in the planning and in the operation of systems of reservoirs. Two approach types can be adopted for the solution of this problem type: traditional approach, based on techniques of operational research, and approach by intelligent systems (artificial intelligence – AI). The Models in AI have as main characteristic the flexibility of inclusion of expressed rules in a language of easy understanding that incorporate in the modeling the specialized knowledge and the experience of the operators. In spite of the importance of the subject and of the potential of the techniques, the apprenticeship of current development is lacking of theoretical recital that it systematizes the actors' practice in the processes. Researches that close this gap are necessary so that better is known the advantages and disadvantages of the applied Intelligent Systems to the operation of systems of reservoirs. Techniques based on fuzzy logic, artificial neural networks and neuro-diffuse hybrid systems were chosen for test. The objective of the research is to investigate the potential of these techniques for the process of decision in the operation of systems of reservoirs. The definitions and implementations of the methodological outlines proposed in this research and their applications in the study of case of the system that supplies the metropolitan area of Fortaleza confirmed the hypothesis of the research for two of the three appraised techniques – the models based in fuzzy logic and the models based in artificial neural networks. The third tested technique – Adaptive Network Based Fuzzy Inference System – presented unsatisfactory results. The main contributions of this research to the state of the art are: definition of methodological outlines using approaches based in intelligent systems in the obtaining of operational politics for systems of reservoirs in semi-arid areas; inclusion, in the intelligent systems for obtaining of operational politics, of semantic variables (qualitative) indicative of the climatic forecast, evaluating as much the improvement of the process of operation of the reservoirs as the current potential mistakes of mistaken forecasts; use, together, of clustering techniques and of learning in the construction of diffuse expert systems for operation of systems of reservoirs; construction and use, for the diffuse expert systems of operation of reservoirs, of assigned models, avoiding the "Lack of Knowledge".

SUMÁRIO

1 – INTRODUÇÃO	2
1.1 – CONTEXTUALIZAÇÃO E JUSTIFICATIVA DA PESQUISA.....	2
1.2 – OBJETIVOS DA PESQUISA	4
1.3 – ESTRUTURAÇÃO DO TEXTO	5
2 – REVISÃO BIBLIOGRÁFICA	8
2.1 – INTRODUÇÃO	8
2.2 – OS RECURSOS TRADICIONAIS	9
2.2.1 – <i>Introdução</i>	9
2.2.2 – <i>A Programação Linear</i>	10
2.2.2.1 – Conceitos Básicos e Aspectos Fundamentais.....	10
2.2.2.2 – Aplicações.....	12
2.2.3 – <i>A Programação Dinâmica</i>	15
2.2.3.1 – Conceitos Básicos e Aspectos Fundamentais.....	15
2.2.3.2 – Aplicações.....	19
2.2.4 – <i>A Simulação</i>	25
2.2.4.1 – Conceitos Básicos e Aspectos Fundamentais.....	25
2.2.4.2 – Aplicações.....	27
2.3 – AS TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL	30
2.3.1 – <i>Lógica Fuzzy ou Difusa</i>	30
2.3.2 – <i>Redes Neurais Artificiais</i>	35
2.3.3 – <i>Sistemas Neuro-Difusos</i>	40
2.3.4 – <i>Aplicações</i>	42
2.3.4.1 – Inteligência Artificial e Recursos Hídricos	42
2.3.4.2 – Lógica Difusa e Operação de Reservatórios	50
2.3.4.3 – Redes Neurais Artificiais e Operação de Reservatórios	53
2.3.4.4 – Sistemas Neuro-Difusos e Operação de Reservatórios	55
2.4 – COMPARAÇÃO ENTRE TÉCNICAS TRADICIONAIS E BASEADAS EM INTELIGÊNCIA ARTIFICIAL	56
3 – MATERIAIS E MÉTODOS.....	60
3.1 – INTRODUÇÃO	60
3.2 – SISTEMA DE RESERVATÓRIOS PARA ANÁLISE.....	61
3.2.1 – <i>Descrição Física do Sistema</i>	61
3.2.2 – <i>Dados Básicos</i>	64
3.3 – METODOLOGIAS	70
3.3.1 – <i>Técnica para Geração da Biblioteca de Conhecimentos: Programação Dinâmica</i>	70
3.3.1.1 – Programação Dinâmica Tradicional.....	70
3.3.1.2 – Programação Dinâmica Incremental	72
3.3.2 – <i>Técnica (Modelo) de Simulação e a Política Operacional Heurística</i>	74
3.3.3 – <i>Abordagens (Metodologias) Tradicionais</i>	76
3.3.4 – <i>Metodologias baseadas em Inteligência Artificial (IA)</i>	78
3.3.4.1 – Modelo baseado em Lógica Difusa.....	78
3.3.4.2 – Modelo baseado em Redes Neurais Artificiais	85
3.3.4.3 – Modelo Híbrido: Sistema de Inferência Adaptativo Neuro-Difuso.....	89
3.4 – SUBSÍDIOS PARA ANÁLISE	90
3.4.1 – <i>Cenários Hidrológicos</i>	90
3.4.2 – <i>Função-Objetivo utilizada na Otimização</i>	91
3.4.3 – <i>Indicadores de Desempenho e Graus de Eficiência</i>	92

4 – APLICAÇÃO E RESULTADOS	95
4.1 – INTRODUÇÃO	95
4.2 – A BIBLIOTECA DE CONHECIMENTOS: COMPOSIÇÃO E INDICADORES DE DESEMPENHO	95
4.3 – A POLÍTICA OPERACIONAL HEURÍSTICA.....	96
4.4 – AS ABORDAGENS TRADICIONAIS.....	97
4.4.1 – Modelos Baseados em Análise de Regressão (PDIR).....	97
4.4.2 – Modelo baseado em Zoneamento dos Reservatórios (PDIZ).....	99
4.5 – AS ABORDAGENS BASEADAS EM INTELIGÊNCIA ARTIFICIAL	103
4.5.1 – Modelos baseados em Lógica Difusa (PDID)	103
4.5.2 – Modelos baseados em Redes Neurais Artificiais (PDIN)	110
4.5.3 – Modelos Neuro-Difusos (PDIANFIS).....	118
4.6 – ANÁLISES COMPARATIVAS	124
4.7 – ANÁLISE DA INCLUSÃO DE VARIÁVEIS QUALITATIVAS (SEMÂNTICAS)	135
4.8 – ANÁLISE DO USO DE MODELOS HIERARQUICAMENTE ESCALONADOS	139
5 – CONCLUSÕES E RECOMENDAÇÕES	141
5.1 – CONCLUSÕES E CONTRIBUIÇÕES AO ESTADO DA ARTE	141
5.2 – RECOMENDAÇÕES	144
REFERÊNCIAS BIBLIOGRÁFICAS	147
ANEXO I – BIBLIOTECA DE CONHECIMENTOS	158
ANEXO II – MODELAGEM POR LÓGICA DIFUSA – ANÁLISE DOS AGRUPAMENTOS.....	163
ANEXO III – MODELAGEM POR REDES NEURAS ARTIFICIAIS – VALORES DO INDICADOR DE ERRO.....	180

LISTA DE ABREVIATURAS

ANFIS	Adaptive Network Based Fuzzy Inference System
BC	Biblioteca de Conhecimentos
CB	Custo de Bombeamento
CF	Custo de Falha
EPMA	Erro Percentual Médio Absoluto
FAM	Fuzzy Associative Memory
Fc ou Pd	Coefficiente de Partição Difusa
Fcsig ou Pdsig	Coefficiente de Partição Difusa significativa
FO	Função-objetivo
GEC	Grau de Eficiência nos Custos
GEP	Grau de Eficiência nas Perdas
IA	Inteligência Artificial
LD	Lógica Difusa
MHE	Modelos Hierarquicamente Escalonados
MLP	Perceptron Multicamadas
PD	Programação Dinâmica
PDA	Programação Dinâmica Amostral
PDAS	Programação Dinâmica de Aproximação Sucessiva
PDD	Programação Dinâmica Discreta
PDDD	Programação Dinâmica Diferencial Discreta
PDDif	Programação Dinâmica Diferencial
PDE	Programação Dinâmica Estocástica
PDEA	Programação Dinâmica Estocástica Amostral
PDEB	Programação Dinâmica Estocástica Bayesiana
PDEDif	Programação Dinâmica Estocástica Diferencial
PDEG	Programação Dinâmica Estocástica com Gradiente
PDEP	Programação Dinâmica Estocástica Paramétrica
PDI	Programação Dinâmica Incremental
PDIANFIS	Modelo conjunto de Programação Dinâmica Incremental e Algoritmo ANFIS
PDID	Modelo conjunto de Programação Dinâmica Incremental e Lógica Difusa
PDIN	Modelo conjunto de Programação Dinâmica Incremental e Redes Neurais Artificiais
PDIR	Modelo conjunto de Programação Dinâmica Incremental e Análise de Regressão
PDIZ	Modelo conjunto de Programação Dinâmica Incremental e Zoneamento dos Reservatórios
PL	Programação Linear
PLS	Programação Linear Sucessiva
PNL	Programação Não-Linear
PO	Política Operacional
POH	Política Operacional Heurística
POR	Política Operacional resultante do modelo PDIR
POZ	Política Operacional resultante do modelo PDIZ
QGav	Vazão Afluente ao Açude Gavião
QPac	Vazão Afluente ao Açude Pacajus

QPcr	Vazão Afluente aos Açudes Pacoti/Riachão
RCI	Regra de Composição de Inferência
RMF	Região Metropolitana de Fortaleza
RNA	Rede Neural Artificial
SBLD	Sistemas baseados em Lógica Difusa
SDR	Sistema Difuso de Regras
SED	Sistema Especialista Difuso
TBD	Teoria Bayesiana de Decisão
TCD	Teoria dos Conjuntos Difusos
UCnl	Retirada do Canal do Trabalhador
UGav	Retirada do Açude Gavião
UPac	Retirada do Açude Pacajus
UPcr	Retirada dos Açudes Pacoti/Riachão
VAT	Vazão Afluente Total ao Sistema
Vd	Índice de Validade do Agrupamento
VGav	Volume do Açude Gavião
VPac	Volume do Açude Pacajus
VPer	Volume dos Açudes Pacoti/Riachão
VTs	Volume Total do Sistema

LISTA DE FIGURAS

FIGURA 2.1 – REPRESENTAÇÃO ESQUEMÁTICA DE UM NEURÔNIO ARTIFICIAL	36
FIGURA 2.2 – ORGANIZAÇÃO EM CAMADAS DAS REDES NEURAIS ARTIFICIAIS	37
FIGURA 2.3 – ARQUITETURA DO SISTEMA DE INFERÊNCIA ADAPTATIVO NEURO-DIFUSO (ANFIS).....	41
FIGURA 3.1A – REPRESENTAÇÃO ESQUEMÁTICA DO SISTEMA INTEGRADO DE ABASTECIMENTO DA REGIÃO METROPOLITANA DE FORTALEZA (RMF).....	62
FIGURA 3.1B – DIAGRAMA UNIFILAR DO SISTEMA UTILIZADO NO ESTUDO DE CASO.....	62
FIGURA 3.2 – DISTRIBUIÇÃO TEMPORAL DE VARIÁVEIS CLIMATOLÓGICAS NA BACIA DO AÇUDE GAVIÃO.....	66
FIGURA 3.3 – DISTRIBUIÇÃO TEMPORAL DE VARIÁVEIS CLIMATOLÓGICAS NAS BACIAS DOS AÇUDES PACOTI E RIACHÃO	66
FIGURA 3.4 – DISTRIBUIÇÃO TEMPORAL DE VARIÁVEIS CLIMATOLÓGICAS NA BACIA DO AÇUDE PACAJUS.....	67
FIGURA 3.5 – DEFLÚVIOS AFLUENTES AO RESERVATÓRIO GAVIÃO (1912 A 1996)	67
FIGURA 3.6 – DEFLÚVIOS AFLUENTES AOS RESERVATÓRIOS PACOTI/RIACHÃO (1912 A 1996)	68
FIGURA 3.7 – DEFLÚVIOS AFLUENTES AO RESERVATÓRIO PACAJUS (1912 A 1996)	68
FIGURA 3.8 – CURVA COTA X ÁREA X VOLUME DO GAVIÃO	69
FIGURA 3.9 – CURVA COTA X ÁREA X VOLUME DO PACOTI/RIACHÃO	69
FIGURA 3.10 – CURVA COTA X ÁREA X VOLUME DO PACAJUS	69
FIGURA 3.11 – ESQUEMAS METODOLÓGICOS UTILIZADOS NA PESQUISA	70
FIGURA 3.12 – TRAJETÓRIA TENTATIVA E SEU CORREDOR PARA A VARIÁVEL DE ESTADO NA PDI.....	73
FIGURA 3.13 (A) – SOLUÇÃO PARA AS VARIÁVEIS DENTRO DO CORREDOR	73
FIGURA 3.13 (B) – DEFINIÇÃO DE UM NOVO CORREDOR	74
FIGURA 3.14 – ESQUEMA DE ZONEAMENTO DOS RESERVATÓRIOS DO SISTEMA	77
FIGURA 3.15 – ESQUEMA GERAL DE DEFINIÇÃO DA CONFIGURAÇÃO INICIAL DOS SISTEMAS ESPECIALISTAS DIFUSOS A PARTIR DA ANÁLISE DE AGRUPAMENTO	82
FIGURA 3.16 – TIPOS DE FUNÇÃO DE PERTINÊNCIA TESTADOS NA PESQUISA	82
FIGURA 3.17 – ALGORITMO DE PESQUISA DAS REGRAS NA MATRIZ COGNITIVA.....	84
FIGURA 3.18 – TIPOS DE FUNÇÕES DE TRANSFERÊNCIA TESTADOS NA PESQUISA.....	87
FIGURA 4.1 – HISTOGRAMAS MENSAIS DE FREQUÊNCIA DA TRANSFERÊNCIA DE ÁGUA DO CANAL DO TRABALHADOR PARA O RESERVATÓRIO PACAJUS.....	100
FIGURA 4.2 – HISTOGRAMAS MENSAIS DE FREQUÊNCIA DA TRANSFERÊNCIA DE ÁGUA DO RESERVATÓRIO PACAJUS PARA OS RESERVATÓRIOS PACOTI/RIACHÃO.....	101
FIGURA 4.3 – HISTOGRAMAS MENSAIS DE FREQUÊNCIA DA TRANSFERÊNCIA DE ÁGUA DOS RESERVATÓRIOS PACOTI/RIACHÃO PARA O RESERVATÓRIO GAVIÃO	102
FIGURA 4.4 – ESQUEMA GERAL DOS SISTEMAS ESPECIALISTAS DIFUSOS UTILIZADOS	103
FIGURA 4.5 – ESQUEMA DE UTILIZAÇÃO DOS MODELOS HIERARQUICAMENTE ESCALONADOS.....	105
FIGURA 4.6 – ESQUEMA GERAL DAS REDES NEURAIS ARTIFICIAIS UTILIZADAS	111
FIGURA 4.7 – VARIAÇÃO DO EPMA EM FUNÇÃO DO NÚMERO DE NÓS NA PRIMEIRA CAMADA OCULTA.....	115
FIGURA 4.8 – VARIAÇÃO DO EPMA EM FUNÇÃO DO NÚMERO DE NÓS NA SEGUNDA CAMADA OCULTA	117
FIGURA 4.9 – ESQUEMA GERAL DOS SISTEMAS DE INFERÊNCIA ADAPTATIVOS NEURO-DIFUSOS (ANFIS) UTILIZADOS	119
FIGURA 4.10 – TRAJETÓRIAS DO VOLUME TOTAL DO SISTEMA (VTS) OBTIDAS PELOS DIVERSOS TIPOS DE ABORDAGEM – CENÁRIO DE LONGO PRAZO	127
FIGURA 4.11 – TRAJETÓRIAS DAS RETIRADAS DOS AÇUDES PACOTI/RIACHÃO OBTIDAS PELOS DIVERSOS TIPOS DE ABORDAGEM – CENÁRIO DE LONGO PRAZO	127
FIGURA 4.12 – TRAJETÓRIAS DAS RETIRADAS DO AÇUDE PACAJUS OBTIDAS PELOS DIVERSOS TIPOS DE ABORDAGEM – CENÁRIO DE LONGO PRAZO	128
FIGURA 4.13 – TRAJETÓRIAS DAS RETIRADAS DO CANAL DO TRABALHADOR OBTIDAS PELOS DIVERSOS TIPOS DE ABORDAGEM – CENÁRIO DE LONGO PRAZO	128
FIGURA 4.14 – PDIR X PDIN – COMPARAÇÃO DE CUSTOS E PERDAS HÍDRICAS – CENÁRIO DE CURTO PRAZO DO TIPO SECO.	129
FIGURA 4.15 – PDIR X PDIN – COMPARAÇÃO DE CUSTOS E PERDAS HÍDRICAS – CENÁRIO DE CURTO PRAZO DO TIPO NORMAL.	129
FIGURA 4.16 – PDIR X PDIN – COMPARAÇÃO DE CUSTOS E PERDAS HÍDRICAS – CENÁRIO DE CURTO PRAZO DO TIPO ÚMIDO	130
FIGURA 4.17 – PDIZ X PDID – COMPARAÇÃO DE CUSTOS E PERDAS HÍDRICAS – CENÁRIO DE CURTO PRAZO DO TIPO SECO.	131
FIGURA 4.18 – PDIZ X PDID – COMPARAÇÃO DE CUSTOS E PERDAS HÍDRICAS – CENÁRIO DE CURTO PRAZO DO TIPO NORMAL.	131

FIGURA 4.19 – PDIZ x PDID – COMPARAÇÃO DE CUSTOS E PERDAS HÍDRICAS – CENÁRIO DE CURTO PRAZO DO TIPO ÚMIDO	132
FIGURA 4.20 – PDIN x PDID – COMPARAÇÃO DE CUSTOS E PERDAS HÍDRICAS – CENÁRIO DE CURTO PRAZO DO TIPO SECO.	133
FIGURA 4.21 – PDIN x PDID – COMPARAÇÃO DE CUSTOS E PERDAS HÍDRICAS – CENÁRIO DE CURTO PRAZO DO TIPO NORMAL.	133
FIGURA 4.22 – PDIN x PDID – COMPARAÇÃO DE CUSTOS E PERDAS HÍDRICAS – CENÁRIO DE CURTO PRAZO DO TIPO ÚMIDO	134

LISTA DE TABELAS

TABELA 3.1 – CARACTERÍSTICAS DAS ESTAÇÕES ELEVATÓRIAS.....	64
TABELA 3.2 – CLASSIFICAÇÃO DOS CENÁRIOS HIDROLÓGICOS.....	91
TABELA 3.3 – TIPO DE UTILIZAÇÃO DOS CENÁRIOS HIDROLÓGICOS	91
TABELA 4.1 – ABREVIATURAS E DESCRIÇÃO DAS VARIÁVEIS DE ENTRADA UTILIZADAS PARA IDENTIFICAÇÃO DOS MODELOS.....	95
TABELA 4.2 – INDICADORES DO SISTEMA FÍSICO BASEADOS NA BIBLIOTECA DE CONHECIMENTOS – CENÁRIOS DE MÉDIO PRAZO PARA COMPARAÇÃO	96
TABELA 4.3 – INDICADORES DO SISTEMA FÍSICO E GRAUS DE EFICIÊNCIA DA POLÍTICA OPERACIONAL HEURÍSTICA – CENÁRIOS DE COMPARAÇÃO	97
TABELA 4.4 – MODELOS MATEMÁTICOS PARA ANÁLISES DE REGRESSÃO	98
TABELA 4.5 – INDICADOR DE DESEMPENHO – MODELOS BASEADOS EM ANÁLISE DE REGRESSÃO	98
TABELA 4.6 – INDICADORES DO SISTEMA FÍSICO E GRAUS DE EFICIÊNCIA DO MODELO BASEADO EM ANÁLISE DE REGRESSÃO – CENÁRIOS DE COMPARAÇÃO	99
TABELA 4.7 – INDICADORES DO SISTEMA FÍSICO E GRAUS DE EFICIÊNCIA DO MODELO BASEADO EM ZONEAMENTO DOS RESERVATÓRIOS – CENÁRIOS DE COMPARAÇÃO	99
TABELA 4.8 – MODELOS DE SISTEMAS ESPECIALISTAS DIFUSOS	104
TABELA 4.9 – NÚMERO DE AGRUPAMENTOS DIFUSOS – MODELOS QUANTITATIVOS DE SISTEMAS ESPECIALISTAS DIFUSOS	106
TABELA 4.10 – INDICADOR DE DESEMPENHO – MODELOS BASEADOS EM LÓGICA DIFUSA – SEDS COM REGRAS HEURÍSTICAS – MODELOS QUANTITATIVOS	106
TABELA 4.11 – INDICADOR DE DESEMPENHO – MODELOS BASEADOS EM LÓGICA DIFUSA – SEDS COM REGRAS OBTIDAS POR TREINAMENTO ORGANIZATIVO – MODELOS QUANTITATIVOS	107
TABELA 4.12 – MODELOS BASEADOS EM LÓGICA DIFUSA – MODELOS QUANTITATIVO-SAZONAIS ADOTADOS	107
TABELA 4.13 – INDICADOR DE DESEMPENHO – MODELOS BASEADOS EM LÓGICA DIFUSA – MODELOS QUANTITATIVO-SAZONAIS	108
TABELA 4.14 – MODELOS BASEADOS EM LÓGICA DIFUSA – MODELOS QUALI-QUANTITATIVOS ADOTADOS	108
TABELA 4.15 – INDICADOR DE DESEMPENHO – MODELOS BASEADOS EM LÓGICA DIFUSA – MODELOS QUALI-QUANTITATIVOS.....	109
TABELA 4.16 – ANÁLISE DO USO DE DIFERENTES TIPOS DE FUNÇÕES DE PERTINÊNCIA – MODELO BASEADO EM LÓGICA DIFUSA.....	109
TABELA 4.17 – INDICADORES DO SISTEMA FÍSICO E GRAUS DE EFICIÊNCIA DO MODELO BASEADO EM LÓGICA DIFUSA – CENÁRIOS DE COMPARAÇÃO	110
TABELA 4.18 – MODELOS DE REDES NEURAIS ARTIFICIAIS	111
TABELA 4.19 – INDICADOR DE DESEMPENHO – MODELOS BASEADOS EM REDES NEURAIS – MODELOS QUANTITATIVOS.....	112
TABELA 4.20 – INDICADOR DE DESEMPENHO – MODELOS BASEADOS EM REDES NEURAIS – MODELOS QUANTITATIVO-SAZONAIS	113
TABELA 4.21 – INDICADOR DE DESEMPENHO – MODELOS BASEADOS EM REDES NEURAIS – MODELOS QUALI-QUANTITATIVOS.....	114
TABELA 4.22 – ANÁLISE DO USO DE DIFERENTES TIPOS DE FUNÇÕES DE TRANSFERÊNCIA – MODELO BASEADO EM REDES NEURAIS ARTIFICIAIS	115
TABELA 4.23 – INDICADORES DO SISTEMA FÍSICO E GRAUS DE EFICIÊNCIA DO MODELO BASEADO EM REDES NEURAIS ARTIFICIAIS – CENÁRIOS DE COMPARAÇÃO	118
TABELA 4.24 – MODELOS ANFIS	120
TABELA 4.25 – INDICADOR DE DESEMPENHO – MODELOS NEURO-DIFUSOS – MODELOS QUANTITATIVOS	120
TABELA 4.26 – MODELOS NEURO-DIFUSOS – MODELOS QUANTITATIVO-SAZONAIS ADOTADOS.....	121
TABELA 4.27 – INDICADOR DE DESEMPENHO – MODELOS NEURO-DIFUSOS – MODELOS QUANTITATIVO-SAZONAIS	122
TABELA 4.28 – MODELOS NEURO-DIFUSOS – MODELOS QUALI-QUANTITATIVOS ADOTADOS.....	122
TABELA 4.29 – INDICADOR DE DESEMPENHO – MODELOS NEURO-DIFUSOS – MODELOS QUALI-QUANTITATIVOS	123
TABELA 4.30 – ANÁLISE DO USO DE DIFERENTES TIPOS DE FUNÇÕES DE PERTINÊNCIA – MODELOS NEURO-DIFUSOS	123
TABELA 4.31 – INDICADORES DO SISTEMA FÍSICO E GRAUS DE EFICIÊNCIA DO MODELO BASEADO EM LÓGICA DIFUSA – CENÁRIOS DE COMPARAÇÃO	124
TABELA 4.32 – COMPARAÇÃO ENTRE OS CUSTOS OPERACIONAIS PARA AS DIVERSAS ABORDAGENS	124
TABELA 4.33 – COMPARAÇÃO ENTRE AS PERDAS HÍDRICAS PARA AS DIVERSAS ABORDAGENS	125

TABELA 4.34 – MODELOS COMPARADOS NA ANÁLISE DE INCLUSÃO DA VARIÁVEL DE PREVISÃO CLIMÁTICA.	135
TABELA 4.35 – ANÁLISE DA INCLUSÃO DE VARIÁVEL SEMÂNTICA – MODELOS BASEADOS EM LÓGICA DIFUSA (PDID)	136
TABELA 4.36 – ANÁLISE DA INCLUSÃO DE VARIÁVEL SEMÂNTICA - MODELOS BASEADOS EM REDES NEURAIS ARTIFICIAIS (PDIN)	136
TABELA 4.37 – ANÁLISE DO IMPACTO DE ERROS NAS PREVISÕES CLIMÁTICAS – MODELOS BASEADOS EM LÓGICA DIFUSA (PDID)	138
TABELA 4.38 – ANÁLISE DO IMPACTO DE ERROS NAS PREVISÕES CLIMÁTICAS – MODELOS BASEADOS EM REDES NEURAIS ARTIFICIAIS (PDIN)	138
TABELA 4.39 – ANÁLISE DO USO DE MODELOS HIERARQUICAMENTE ESCALONADOS	139
TABELA I.1 – BIBLIOTECA DE CONHECIMENTOS – VALORES ÓTIMOS DAS RETIRADAS DO AÇUDES PACOTI/RIACHÃO	158
TABELA I.1 – BIBLIOTECA DE CONHECIMENTOS – VALORES ÓTIMOS DAS RETIRADAS DO AÇUDES PACOTI/RIACHÃO	158
TABELA I.2 – BIBLIOTECA DE CONHECIMENTOS – VALORES ÓTIMOS DAS RETIRADAS DO AÇUDE PACAJUS....	159
TABELA I.3 – BIBLIOTECA DE CONHECIMENTOS – VALORES ÓTIMOS DAS RETIRADAS DO CANAL DO TRABALHADOR.....	161
TABELA II.1A – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DOS AÇUDES PACOTI/RIACHÃO – MODELO MBASESED	163
TABELA II.1B – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DO AÇUDE PACAJUS – MODELO MBASESED	163
TABELA II.1C – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DO CANAL DO TRABALHADOR – MODELO MBASESED	163
TABELA II.2A – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DOS AÇUDES PACOTI/RIACHÃO – MODELO MBASESED	163
TABELA II.2B – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DO AÇUDE PACAJUS – MODELO MBASESED	164
TABELA II.2C – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DO CANAL DO TRABALHADOR – MODELO MBASESED.....	164
TABELA II.3A – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DOS AÇUDES PACOTI/RIACHÃO – MODELO M01SED	164
TABELA II.3B – AGRUPAMENTO – COEFICIENTES DE EFICIÊNCIA – RETIRADA DO AÇUDE PACAJUS– MODELO M01SED	164
TABELA II.3C – AGRUPAMENTO – COEFICIENTES DE EFICIÊNCIA – RETIRADA DO CANAL DO TRABALHADOR– MODELO M01SED	165
TABELA II.4A – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DOS AÇUDES PACOTI/RIACHÃO– MODELO M01SED.....	165
TABELA II.4B – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DO AÇUDE PACAJUS– MODELO M01SED	165
TABELA II.4C – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DO CANAL DO TRABALHADOR– MODELO M01SED	165
TABELA II.5A – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DOS AÇUDES PACOTI/RIACHÃO – MODELO M02SED	166
TABELA II.5B – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DO AÇUDE PACAJUS – MODELO M02SED	166
TABELA II.5C – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DO CANAL DO TRABALHADOR – MODELO M02SED	166
TABELA II.6A – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DOS AÇUDES PACOTI/RIACHÃO – MODELO M02SED.....	166
TABELA II.6B – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DO AÇUDE PACAJUS – MODELO M02SED	167
TABELA II.6C – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DO CANAL DO TRABALHADOR – MODELO M02SED	167
TABELA II.7A – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DOS AÇUDES PACOTI/RIACHÃO – MODELO M03SED	167
TABELA II.7B – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DO AÇUDE PACAJUS – MODELO M03SED	167
TABELA II.7C – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DO CANAL DO TRABALHADOR – MODELO M03SED	168
TABELA II.8A – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DOS AÇUDES PACOTI/RIACHÃO – MODELO M03SED.....	168

TABELA II.18B – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DO AÇUDE PACAJUS – MODELO M08SED	176
TABELA II.18C – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DO CANAL DO TRABALHADOR – MODELO M08SED	176
TABELA II.19A – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DOS AÇUDES PACOTI/RIACHÃO – MODELO M09SED	176
TABELA II.19B – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DO AÇUDE PACAJUS – MODELO M09SED	176
TABELA II.19C – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DO CANAL DO TRABALHADOR – MODELO M09SED	177
TABELA II.20A – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DOS AÇUDES PACOTI/RIACHÃO – MODELO M09SED	177
TABELA II.20B – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DO AÇUDE PACAJUS – MODELO M09SED	177
TABELA II.20C – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DO CANAL DO TRABALHADOR – MODELO M09SED	177
TABELA II.21A – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DOS AÇUDES PACOTI/RIACHÃO – MODELO M10SED	178
TABELA II.21B – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DO AÇUDE PACAJUS – MODELO M10SED	178
TABELA II.21C – AGRUPAMENTOS – COEFICIENTES DE EFICIÊNCIA – RETIRADA DO CANAL DO TRABALHADOR – MODELO M10SED	178
TABELA II.22A – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DOS AÇUDES PACOTI/RIACHÃO – MODELO M10SED	178
TABELA II.22B – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DO AÇUDE PACAJUS – MODELO M10SED	179
TABELA II.22C – AGRUPAMENTOS – PROTÓTIPOS PARA ORIENTAÇÃO DA DEFINIÇÃO DE REGRAS HEURÍSTICAS – RETIRADA DO CANAL DO TRABALHADOR – MODELO M10SED	179
TABELA III.1 – INDICADOR DE DESEMPENHO – MODELO M01RNA –VALORES MÉDIOS	180
TABELA III.2 – INDICADOR DE DESEMPENHO – MODELO M01RNA –VALORES INDIVIDUALIZADOS	180
TABELA III.3 – INDICADOR DE DESEMPENHO – MODELO M02RNA –VALORES MÉDIOS	181
TABELA III.4 – INDICADOR DE DESEMPENHO – MODELO M02RNA –VALORES INDIVIDUALIZADOS	181
TABELA III.4 – INDICADOR DE DESEMPENHO – MODELO M03RNA –VALORES MÉDIOS	182
TABELA III.5 – INDICADOR DE DESEMPENHO – MODELO M03RNA –VALORES INDIVIDUALIZADOS	182
TABELA III.6 – INDICADOR DE DESEMPENHO – MODELO M04RNA –VALORES MÉDIOS	183
TABELA III.7 – INDICADOR DE DESEMPENHO – MODELO M04RNA –VALORES INDIVIDUALIZADOS	183
TABELA III.8 – INDICADOR DE DESEMPENHO – MODELO M05RNA –VALORES MÉDIOS	184
TABELA III.9 – INDICADOR DE DESEMPENHO – MODELO M05RNA –VALORES INDIVIDUALIZADOS	184
TABELA III.10 – INDICADOR DE DESEMPENHO – MODELO M06RNA –VALORES MÉDIOS	185
TABELA III.11 – INDICADOR DE DESEMPENHO – MODELO M06RNA –VALORES INDIVIDUALIZADOS	185
TABELA III.12 – INDICADOR DE DESEMPENHO – MODELO M07RNA –VALORES MÉDIOS	186
TABELA III.13 – INDICADOR DE DESEMPENHO – MODELO M07RNA –VALORES INDIVIDUALIZADOS	186
TABELA III.14 – INDICADOR DE DESEMPENHO – MODELO M08RNA –VALORES MÉDIOS	187
TABELA III.15 – INDICADOR DE DESEMPENHO – MODELO M08RNA –VALORES INDIVIDUALIZADOS	187
TABELA III.16 – INDICADOR DE DESEMPENHO – MODELO M09RNA –VALORES MÉDIOS	188
TABELA III.17 – INDICADOR DE DESEMPENHO – MODELO M09RNA –VALORES INDIVIDUALIZADOS	188
TABELA III.18 – INDICADOR DE DESEMPENHO – MODELO M01sRNA –VALORES MÉDIOS	189
TABELA III.19 – INDICADOR DE DESEMPENHO – MODELO M01sRNA –VALORES INDIVIDUALIZADOS	189
TABELA III.20 – INDICADOR DE DESEMPENHO – MODELO M02sRNA –VALORES MÉDIOS	190
TABELA III.21 – INDICADOR DE DESEMPENHO – MODELO M02sRNA –VALORES INDIVIDUALIZADOS	190
TABELA III.22 – INDICADOR DE DESEMPENHO – MODELO M03sRNA –VALORES MÉDIOS	191
TABELA III.23 – INDICADOR DE DESEMPENHO – MODELO M03sRNA –VALORES INDIVIDUALIZADOS	191
TABELA III.24 – INDICADOR DE DESEMPENHO – MODELO M04sRNA –VALORES MÉDIOS	192
TABELA III.25 – INDICADOR DE DESEMPENHO – MODELO M04sRNA –VALORES INDIVIDUALIZADOS	192
TABELA III.26 – INDICADOR DE DESEMPENHO – MODELO M01qRNA –VALORES MÉDIOS	193
TABELA III.27 – INDICADOR DE DESEMPENHO – MODELO M01qRNA –VALORES INDIVIDUALIZADOS	193
TABELA III.29 – INDICADOR DE DESEMPENHO – MODELO M02qRNA –VALORES INDIVIDUALIZADOS	194

CAPÍTULO 1 – INTRODUÇÃO

1 – INTRODUÇÃO

1.1 – CONTEXTUALIZAÇÃO E JUSTIFICATIVA DA PESQUISA

O uso de modelos matemáticos na análise de sistemas de recursos hídricos tem se desenvolvido bastante desde a década de 1960. A principal razão para esse desenvolvimento é o fato de esses modelos serem a única maneira de se obter discernimento no planejamento e na operação de sistemas com certo grau de complexidade. Outras fortes razões para o acentuado desenvolvimento desses modelos foram o advento e os contínuos avanços da tecnologia dos computadores digitais. Esses avanços tecnológicos permitiram reduzir custos operacionais, aumentar a eficiência e a produtividade dos sistemas e aumentar a confiabilidade dos resultados, possibilitando o estudo de sistemas considerados anteriormente inviáveis.

Uma das principais áreas de aplicação dos modelos de análise de sistemas de recursos hídricos é no planejamento e na operação de sistemas de reservatórios. Dois tipos de abordagem podem ser adotados para a solução desse tipo de problema, quais sejam: abordagem tradicional (recursos tradicionais), baseada em técnicas de pesquisa operacional, e abordagem por sistemas inteligentes.

A pesquisa operacional foi uma técnica introduzida durante a Segunda Guerra Mundial para a solução de problemas de operações militares, daí seu nome. Trata-se, em última análise, da aplicação do método de Descartes na solução de problemas complexos. Desde sua introdução, a pesquisa operacional tem-se desenvolvido e tem sido aplicada no âmbito civil nas mais diversas modalidades. Deve-se ao Harvard Water Program a ação pioneira de introduzir esse tipo de abordagem em planejamento e gestão dos recursos hídricos. Naquele trabalho, vários pesquisadores do programa apresentaram as bases da chamada análise de sistemas de recursos hídricos. Esta análise de sistemas (ou sistemática) consiste em decompor qualquer problema de planejamento e operação de sistemas de recursos hídricos em cinco etapas: a) definição dos objetivos; b) formulação de medidas quantitativas dos objetivos; c) geração de alternativas de solução; d) quantificação das alternativas; e e) seleção da alternativa ótima. No processo de escolha da alternativa ótima, ao longo dos anos, várias técnicas foram desenvolvidas, sendo as mais conhecidas a programação linear, a programação dinâmica e a simulação. O número de variações

existentes na literatura é bastante extenso. A aplicação em casos reais de engenharia não é tão extensa, mas é suficiente para garantir a sua viabilidade.

O termo *Sistemas Inteligentes* tem sido aplicado a sistemas computacionais pertencentes a uma grande área de estudo da informática. Originalmente, a chamada Inteligência Artificial consistia basicamente nos Sistemas de Regras do tipo “se <premissas> então <conseqüentes>”, com os quais se procurava representar o comportamento decisório, sob forma de respostas às premissas formuladas. Recursos matemáticos mais sofisticados ampliaram a área, tanto em recursos quanto em alcance de utilização.

Atualmente, essa área tem recebido outras denominações, como Inteligência Computacional ou Computação Inteligente. O adjetivo *inteligente* decorre do fato de serem estes sistemas inspirados no comportamento humano ou da natureza, ou que tentam reproduzi-lo. Esta abordagem tem encontrado grande aceitação em variadas aplicações a diversas áreas do conhecimento, muitas vezes superando o desempenho dos recursos convencionais (pesquisa operacional). Em recursos hídricos e demais ciências ambientais, os sistemas computacionais inteligentes encontram aplicações, sobretudo em modelagem, previsão, otimização, operação e controle. Modelos baseados em Inteligência Artificial têm como uma das suas principais características a flexibilidade de inclusão de regras expressas em uma linguagem de fácil compreensão que incorporam na modelagem matemática o conhecimento especializado e a experiência dos operadores, ou seja, a prática vivencial dos técnicos.

Apesar da importância inquestionável do assunto e do grande potencial das técnicas de inteligência artificial, o estágio de desenvolvimento atual é ainda carente de fundamentação teórica que sistematize a prática vivencial dos diversos atores nos processos. A ausência dessa sistematização pode comprometer os potenciais avanços, pela inexistência de uma visão sistêmica ou falta de ferramentas tecnológicas adequadas que possibilitem uma análise, atual e prospectiva, dos fenômenos naturais. Pesquisas que fechem essa lacuna são, portanto, necessárias para que melhor se conheçam as vantagens e desvantagens dos sistemas inteligentes aplicados à operação de sistemas de reservatórios, tendo esse fato motivado a escolha do tema desta pesquisa.

Foram escolhidas para teste, dentro das técnicas de inteligência artificial, aquelas baseadas em lógica difusa e redes neurais artificiais, bem como sistemas híbridos neuro-difusos. Essa escolha teve como fator determinante o fato de essas técnicas serem estimadores de funções livres de modelos matemáticos formais que relacionam as variáveis

de entrada e saída; com elas, as relações são obtidas por meio do aprendizado advindo da experiência.

O sucesso com o qual os sistemas inteligentes têm sido utilizados para modelar sistemas dinâmicos em diversos campos da ciência e da engenharia sugere que as abordagens apresentadas nesta pesquisa possam se mostrar um efetivo e eficiente caminho para modelar sistemas complexos de múltiplos reservatórios, principalmente quando o conhecimento explícito dos subprocessos internos ao sistema não é requerido. Essa é a hipótese desta pesquisa. O fato de as técnicas de lógica difusa e de redes neurais artificiais serem consideradas aproximadores de função universais (KASABOV, 1998) corrobora com esta hipótese. Particularmente sobre as redes neurais, o Teorema de Kolmogorov (KOSKO, 1992) afirma que uma função contínua qualquer pode ser implementada exatamente por meio dessa técnica, respeitada determinada configuração para a rede.

1.2 – OBJETIVOS DA PESQUISA

Investigar o potencial de técnicas de IA – lógica difusa (LD), redes neurais artificiais (RNA) e sistemas neuro-difusos – para o processo de tomada de decisão na operação de sistemas de reservatórios, constitui o objetivo geral desta pesquisa. Como forma de alcançar tal objetivo, propõem-se:

- ✓ a definição de esquemas metodológicos baseados em sistemas inteligentes para a obtenção de políticas operacionais para sistemas de reservatórios;
- ✓ a avaliação comparativa do desempenho de um sistema de reservatórios com políticas operacionais obtidas por abordagens tradicionais e pelos esquemas metodológicos propostos nesta pesquisa.

As análises e avaliações propostas serão feitas a partir de estudo de caso, tendo por base o sistema de reservatórios que abastece a região metropolitana de Fortaleza (RMF). Esse representa um bom teste para os esquemas avaliados, pois: i) localiza-se em uma região de clima semi-árido onde o atendimento das demandas é quase que exclusivamente realizado por reservatórios de regularização, aumentando a importância de eficientes políticas operacionais e ii) apresentou, em passado recente, baixos níveis de acumulação, decorrentes, em parte, de políticas operacionais ineficientes.

Como objetivos complementares a esta pesquisa, tem-se:

- ✓ verificar o potencial das metodologias baseadas em inteligência artificial em comparação com técnicas tradicionais de obtenção de políticas operacionais já consolidadas na literatura e em uso corrente, particularmente em regiões semi-áridas;
- ✓ verificar o impacto da inclusão de variáveis qualitativas (semânticas) de previsão climática na obtenção de políticas operacionais para sistemas de reservatórios;
- ✓ verificar a importância do uso de *Modelos Hierarquicamente Escalonados*¹ nos modelos baseados em lógica difusa para evitar a Falta de Conhecimento².

1.3 – ESTRUTURAÇÃO DO TEXTO

Para sua melhor compreensão, o texto desta tese está dividido em cinco capítulos e três anexos que podem ser assim descritos:

- **Capítulo 1 – Introdução**, ou seja, o presente capítulo, no qual são apresentados a contextualização, a justificativa, os objetivos, a hipótese da pesquisa e a organização geral da tese;
- **Capítulo 2 – Revisão Bibliográfica**, em que se apresentam e se discutem os principais trabalhos já desenvolvidos na área desta pesquisa, procurando, através de uma análise crítica, caracterizar o estado-da-arte da operação de reservatórios. Abordagens tradicionais e baseadas em inteligência artificial são discutidas. O capítulo apresenta também aspectos teóricos gerais sobre as diversas abordagens, visando facilitar o entendimento da discussão dos trabalhos apresentados;
- **Capítulo 3 – Materiais e Métodos**, no qual são descritas as características do sistema de reservatórios utilizado no estudo de caso desta tese e são formalizadas as etapas de implementação das metodologias a serem aplicadas e comparadas. Subsídios para análise, incluindo os indicadores de desempenho, também são apresentados.

¹ Nesta pesquisa, entende-se por *Modelos Hierarquicamente Escalonados* a utilização de modelos matemáticos em seqüência, partindo-se da aplicação do modelo mais complexo (maior número de variáveis) até a aplicação do mais simples (menor número de variáveis), nas situações em que os mais complexos mostrarem-se inadequados.

² Nesta pesquisa, o termo *Falta de Conhecimento* se refere aquelas situações onde não havia uma regra difusa disponível para o conjunto de dados de entrada.

- **Capítulo 4 – Aplicação e Resultados: Apresentação e Discussão**, em que são mostrados os resultados para as diversas abordagens, analisando comparativamente as mesmas. Uma análise da inclusão, nos modelos baseados em técnicas de inteligência artificial, de variáveis qualitativas (semânticas) de previsão climática também é apresentada;
- **Capítulo 5 – Conclusões e Recomendações**, no qual são apresentadas as conclusões da pesquisa e as recomendações de estudos e análises futuras;
- **Anexos:**
 - *Anexo I* – Biblioteca de Conhecimentos;
 - *Anexo II* – Modelagem por Lógica Difusa – Análise dos Agrupamentos;
 - *Anexo III* – Modelagem por Redes Neurais – Valores do Indicador de Erro.

CAPÍTULO 2 – REVISÃO BIBLIOGRÁFICA

2 – REVISÃO BIBLIOGRÁFICA

2.1 – INTRODUÇÃO

A primeira etapa para o estudo de sistemas de reservatórios é a caracterização do problema. Esta consiste na definição dos objetivos e restrições do sistema, transformando a solução do problema na aplicação das diversas técnicas. Problemas complexos podem apresentar milhares de variáveis de decisão e restrições.

Como objetivos a serem atingidos, pode-se ter a minimização dos custos de operação ou das perdas, ou a maximização dos benefícios advindos dos diversos usos atendidos pelo sistema. Isto deve ser obtido garantindo-se um número mínimo de falhas no atendimento das demandas previstas. As restrições típicas em reservatórios incluem equações de conservação de massa (continuidade), armazenamentos máximos e mínimos, limitações impostas pelas tubulações e outros equipamentos, e obrigações contratuais e institucionais as quais o sistema deve satisfazer. Além dessas, deve-se considerar que, qualquer que seja o horizonte para o qual se busca a operação ótima, o estado final do sistema deve garantir abastecimentos futuros.

O resultado procurado é a determinação da política de operação dos reservatórios que atinja os objetivos do problema, respeitando todas as restrições às quais ele está submetido. Em termos simples, política de operação é um conjunto de regras que determinam o armazenamento e a retirada de água do sistema nos diversos períodos de tempo.

A revisão da literatura sobre operação e otimização de reservatórios mostra que não existe um algoritmo geral para esse fim. A escolha da metodologia a ser utilizada em cada caso dependerá das características do sistema de reservatórios, da disponibilidade dos dados e dos objetivos e restrições especificadas.

Este capítulo contém, além desta introdução, três outros grandes itens. O primeiro trata das técnicas de programação matemática utilizadas na engenharia dos recursos hídricos, com ênfase para modelos de operação e otimização de reservatórios. Denominados neste texto de “Recursos Tradicionais”, são apresentados modelos baseados em programação linear (PL), programação dinâmica (PD) e simulação. Os modelos baseados em programação não-linear (PNL) não são discutidos, haja vista não terem essas técnicas a popularidade dos modelos de programação linear e programação dinâmica na análise de sistemas de recursos hídricos. Isso ocorre principalmente porque as resoluções computacionais de modelos de

PNL, se comparadas com as de modelos de PL e PD, são lentas e exigem grande capacidade de armazenamento de dados. Além disso, ao contrário dos modelos de PD, a PNL não apresenta a facilidade de incorporação da natureza estocástica das variáveis hidrológicas. A apresentação, nesta pesquisa, de uma extensa revisão bibliográfica sobre os recursos tradicionais teve por objetivo demonstrar de forma inequívoca a viabilidade de aplicação dessas técnicas para operação de sistemas hídricos, garantindo que as mesmas são bons parâmetros de comparação para os esquemas metodológicos propostos nesta pesquisa. O segundo grande item apresenta a descrição e a aplicação das Técnicas de Inteligência Artificial na engenharia dos recursos hídricos. Novamente com maior ênfase para a operação de reservatórios, são apresentadas e discutidas as técnicas de redes neurais artificiais, aquelas baseadas em lógica fuzzy (ou difusa), e os sistemas híbridos neuro-difusos. Por fim, o último grande item apresenta alguns estudos que compararam, para a área de recursos hídricos, técnicas tradicionais com técnicas fundamentadas em sistemas inteligentes.

A revisão da literatura que segue não tem a intenção de cobrir todos os modelos e as possibilidades existentes. Procurou-se dar uma visão geral das possibilidades de aplicação em recursos hídricos das diversas técnicas, com ênfase maior para aplicações na modelagem da operação de sistemas de reservatórios, visando a uma atualização do estado da arte que permita a definição das abordagens e dos esquemas metodológicos a serem adotados nesta pesquisa.

2.2 – OS RECURSOS TRADICIONAIS

2.2.1 – INTRODUÇÃO

Os modelos tradicionais de obtenção de regras para operação de reservatórios são baseados em técnicas de otimização e simulação. Particularmente os modelos de otimização têm sido amplamente utilizados já que permitem, a partir da série de vazões afluentes ao reservatório, determinar a série de retiradas que maximize ou minimize uma determinada função-objetivo (YEH, 1985; SIMINOVIC, 1992; WURBS, 1993).

Em geral, essas séries de retiradas ótimas têm sido expressas matematicamente a partir de funções que as relacionam com estado do reservatório (volume armazenado) e com as variáveis hidrológicas de entrada, particularmente as vazões afluentes obtidas com técnicas de regressão. Estas relações permitem ao operador do sistema determinar qual a

retirada com base na informação disponível (BHASKAR e WHITLACH, 1987; KARAMOUZ e HOUCK, 1987).

Um modelo para análise de sistemas de recursos hídricos pode ser representado matematicamente por:

$$\max (\text{ou } \min) F(\mathbf{X}), \text{ submetido à } g_i(\mathbf{X}) = b_i, i = 1, 2, \dots, m \quad (2.1)$$

onde $F(\mathbf{X})$ é a função-objetivo, função essa que deve ser otimizada (maximizada ou minimizada); \mathbf{X} é o vetor de variáveis de decisão; e $g_i(\mathbf{X}) = b_i$ são equações que representam as restrições na operação do sistema, b_i sendo parâmetros do modelo. LOUCKS et al. (1981) enfatiza que, por melhor que seja esta representação matemática, esta será uma aproximação do mundo real. A solução ótima obtida pelo modelo é, portanto, ótima somente em relação à definição em particular. Isso é importante para limitar o significado da palavra *ótimo*, comumente usada pelos analistas de sistemas de recursos hídricos.

2.2.2 – A PROGRAMAÇÃO LINEAR

2.2.2.1 – Conceitos Básicos e Aspectos Fundamentais

A técnica de programação linear (PL) tem sido amplamente utilizada para gerenciamento de sistemas de recursos hídricos. A técnica é um caso particular do modelo geral de otimização (eq. 2.1), quando o conjunto de restrições e a função-objetivo são lineares.

O modelo geral de PL pode ser representado por:

$$\max (\text{ou } \min) Z = \mathbf{C}^T \mathbf{X} \quad (2.2)$$

submetido a:

$$\mathbf{A}\mathbf{X} \geq \mathbf{b}, \mathbf{X} \geq 0 \quad (2.3)$$

onde \mathbf{C} é o vetor n -dimensional dos coeficientes da função-objetivo; T indica a operação matricial de transposição; \mathbf{X} é o vetor n -dimensional das variáveis de decisão; \mathbf{b} é o vetor m -dimensional de parâmetros do modelo; \mathbf{A} é a matriz $m \times n$ dos coeficientes das restrições; sendo n é o número de variáveis de decisão; e m é o número de restrições. A teoria de programação linear pode ser encontrada em textos de pesquisa operacional, tais como WAGNER (1969), LUENBERGER (1973) e GOLDBARG e LUNA (2000).

YEH (1985) afirma que as principais vantagens desta técnica, particularmente em operação de sistemas de reservatórios, são: i) a habilidade para se ajustar facilmente a

problemas multidimensionais; ii) a garantia de obtenção de valores ótimos globais; iii) a não necessidade de uma política inicial de operação dos reservatórios; e iv) a existência de pacotes computacionais prontos para a resolução dos problemas.

A principal desvantagem dos métodos de PL é a hipótese de linearidade nas relações, particularmente na função-objetivo. Somente para um conjunto limitado de problemas esta hipótese pode ser aceita sem grande distorção da realidade. Várias técnicas de linearização, tais como linearização por partes, expansões por séries de Taylor de primeira ordem e esquemas iterativos, podem ser usadas com sucesso. LOUCKS et al. (1981) afirmam que, utilizando-se de linearizações, a PL pode ser usada para maximizar funções côncavas, ou para minimizar funções convexas. Estes autores apresentam três métodos para linearização por partes. VIEIRA NETO (1991) descreve três métodos bastante simples para linearização de funções de custo.

Outra desvantagem das técnicas de PL é a otimização em um único estágio (representação estática), enquanto o sistema é dinâmico (variável no tempo). Conseqüentemente, torna-se necessária a repetição da otimização periodicamente, para considerar as mudanças no estado do sistema (VOTRUBA, 1988).

A solução de um problema de PL simples (duas variáveis de decisão) pode ser obtida por meio de gráficos, como ilustra BRAGA JR. (1987, p. 466). Entretanto, o número de variáveis de decisão em problemas de planejamento e operação de sistemas de recursos hídricos é, em geral, muito superior a dois, inviabilizando a solução gráfica. O método simplex e suas variações (simplex revisado, simplex dual etc.) têm sido, então, os mais utilizados na solução de PL aplicada a recursos hídricos. A explicação e a aplicação dos métodos simplex podem ser encontradas em BRAGA JR. (1987), LABADIE (1987), entre outros.

Para problemas de grande escala, existem algoritmos mais eficientes do que o simplex, como é o caso do método primal-dual utilizado no modelo HOPDM (*Higher Order Primal-Dual Method*) apresentado por GONDZIO e MAKOWSKI (1995). Comparando o HOPDM com um modelo baseado no simplex, esses autores concluíram que o aumento da dimensão do problema em geral favorece o método primal-dual. Nos casos estudados, eles obtiveram economias de 10% a 30% no tempo de resolução. Ainda para problemas de grande escala, KUCZERA (1989) afirma que vários modelos de programação linear podem ser formulados por meio de redes (*Network Linear Programs*), para os quais ele afirma serem possíveis códigos computacionais cem vezes mais rápidos do que os códigos de PL

tradicional. Para ilustrar essa técnica, Kuczera mostra uma formulação em rede para um sistema de três reservatórios.

Existem vários pacotes computacionais genéricos para a resolução de problemas de PL. WURBS (1996) cita que, além dos modelos incluídos em planilhas eletrônicas usuais, um dos mais utilizados é o modelo GAMS (*General Algebraic Modeling System*), inicialmente desenvolvido pelo Banco Mundial.

2.2.2.2 – Aplicações

As aplicações de programação linear em recursos hídricos variam desde simples problemas de alocação de recursos até situações complexas de gerenciamento e operação, envolvendo milhares de variáveis de decisão e restrições. As primeiras aplicações aconteceram na década de 1960, no âmbito dos trabalhos do *Harvard Water Resources Group* em que se fez uso de PL em gerenciamento de água subterrânea. Entre os livros-texto que apresentam aplicações de programação linear em sistemas de recursos hídricos merecem destaque: LOUCKS et al. (1981), GOODMAN (1984), BRAGA JR. (1987), VOTRUBA (1988), VOTRUBA e BROZA (1989) e WURBS (1996).

A primeira aplicação de programação linear na operação determinística de reservatórios ocorreu com DORFMAN (1962). Com uma seqüência de exemplos com graus crescentes de complexidade, ele demonstrou como uma técnica de programação matemática pode ser de grande utilidade na análise de projetos de recursos hídricos. Embora os modelos de PL determinística apresentem muitas limitações, importantes aplicações, algumas das quais citadas a seguir, surgiram desde então, demonstrando a utilidade desta técnica.

WINDSOR (1973) desenvolveu uma metodologia que emprega programação linear na otimização (minimização dos prejuízos) da operação de um sistema de múltiplos reservatórios para controle de enchentes. O autor afirma que, embora as hipóteses simplificadoras do modelo por ele denominado PL recursiva distanciem-se bastante da realidade em alguns casos, a metodologia proporciona um grande avanço computacional em relação às metodologias existentes até então.

GRYGIER e STEDINGER (1985) apresentam a comparação entre três modelos determinísticos de otimização – programação linear sucessiva (PLS), combinação de programação linear e programação dinâmica (PL–PD) e um algoritmo de controle ótimo – aplicando-os a um sistema de geração de força hidrelétrica composto de múltiplos reservatórios. O modelo de PLS apresentou os melhores resultados, pois, possuindo um

esforço computacional semelhante ao dos demais métodos, foi o de mais fácil implementação e gerou soluções mais próximas do ótimo global. A PLS consiste em sucessivas soluções de um problema de PL, buscando-se em cada nova solução uma melhor aproximação linear para as não-linearidades do problema original.

ELLIS e ReVELLE (1988) apresentam o desenvolvimento de uma metodologia para transformar problemas não-lineares de maximização de geração de força hidrelétrica com funções não-separáveis em problemas lineares com funções separáveis que podem ser resolvidos por pacotes computacionais de programação linear já disponíveis. Para testar a metodologia, os autores obtiveram a solução de um problema não-linear em sua forma original e a compararam com a solução obtida pela nova metodologia. Eles concluíram que o grande valor desta nova metodologia reside no fato de ela proporcionar uma maneira rápida e eficiente de se obter a solução inicial para ser utilizada em um modelo não-linear, diminuindo o tempo gasto na solução deste último.

CRAWLEY e DANDY (1993) desenvolveram um modelo determinístico de PL para obter políticas de operação ótimas para o sistema de abastecimento da cidade de Adelaide, Austrália. O modelo teve por objetivo a minimização dos custos de bombeamento. A aplicação desse modelo proporcionou uma redução entre 5% e 10% nos custos. Esse modelo é utilizado pelo Engineering and Water Supply Department, órgão responsável pela operação do sistema.

A programação linear tem sido amplamente utilizada na modelagem estocástica de sistemas de reservatórios, existindo diferentes metodologias, tais como: PL estocástica com processos markovianos, programação estocástica com recurso, PL com restrição probabilística, entre outras. LOUCKS et al. (1981) apresentam algumas formulações de programação linear estocástica para sistemas de recursos hídricos. YEH (1985) apresenta uma extensa lista de aplicações de PL estocástica em gerenciamento e operação de reservatórios.

LOUCKS (1968), citado por WURBS (1996), apresenta um modelo estocástico para a operação de um reservatório isolado no qual determina a retirada do reservatório que minimiza a função-objetivo dada pela soma dos quadrados das diferenças entre as retiradas esperadas e os valores reais das mesmas.

LOUCKS e FALKSON (1970) apresentam a incorporação da cadeia de Markov de primeira ordem em otimizações baseadas em programação linear e dinâmica. Os autores

mostram as formulações dos modelos, os algoritmos de solução, as eficiências computacionais e algumas vantagens e limitações destas formulações.

HOUCK e COHON (1978) também utilizaram um processo markoviano de retardo 1 (um) para representação dos escoamentos na elaboração do modelo SESLP (*Sequential Explicit Stochastic Linear Programming Model*) para operação de sistemas de múltiplos reservatórios e múltiplos usos baseado em programação linear. Segundo os autores, esse modelo pode ser utilizado tanto na fase de planejamento como na de operação de sistemas de reservatórios, mas apresenta como grandes limitações o alto esforço computacional e a grande quantidade de dados necessária para sua utilização. Procurando diminuir tais limitações, Houck e Cohon utilizaram com sucesso um algoritmo denominado Scorpio (*System Coordinated Performance-Individual Operation*).

Em outra formulação de programação estocástica, modelos baseados em programação linear são ampliados para que as variáveis aleatórias, além de estarem presentes na função-objetivo, apareçam também nas equações de restrição. YEH (1985) discute e apresenta algumas aplicações desse tipo de formulação denominada programação estocástica com recurso, às vezes também chamada de programação estocástica em dois estágios. O autor enfatiza que, qualquer que seja o problema, a aplicação dessa metodologia apresenta grandes dificuldades.

Uma terceira alternativa dentro dos modelos estocásticos de programação linear é a PL com restrições probabilísticas. Segundo STROBEL (1983), o método de restrições probabilísticas consiste em permitir violações das equações de restrições com certa probabilidade, fixada exteriormente e conhecida como nível de risco. YEH (1985) apresenta a formulação desta técnica e algumas aplicações na operação de reservatórios. HOGAN et al. (1981), citado por YEH (1985), afirmam que essa técnica tem sua aplicabilidade bastante comprometida por não considerar explicitamente nenhuma penalidade para as violações das restrições e por não apresentar, mesmo implicitamente, um recurso para corrigir essas violações.

STROBEL (1983) apresenta um exemplo de aplicação de um modelo modificado de PL com restrições probabilísticas, no qual incorpora uma regra de decisão linear. Diversos outros autores mostram variações desta metodologia (e.g., HOUCK e DATTA, 1981; JOERES et al. 1981; SIMINOVIC e MARIÑO, 1980; SNIEDOVICH, 1980; entre outros).

YEH (1985) ressalta que a principal tarefa das metodologias de programação estocástica em problemas de tomada de decisão sujeitos a incertezas, como é o caso da

operação de sistemas de reservatórios, é a determinação da formulação determinística equivalente. Obtendo-se sucesso nesta tarefa, os procedimentos padrões de otimização matemática podem ser utilizados. Se o modelo determinístico equivalente não puder ser encontrado, a simulação pelo método de Monte Carlo aparece como a alternativa mais viável.

2.2.3 – A PROGRAMAÇÃO DINÂMICA

2.2.3.1 – Conceitos Básicos e Aspectos Fundamentais

A maioria dos problemas operacionais de recursos hídricos tem as decisões levadas a cabo de forma seqüencial no tempo e no espaço, facilitando a sua solução. A programação dinâmica explora essa característica. BELLMAN (2003) definiu programação dinâmica como sendo a teoria dos processos de decisão em múltiplos estágios.

Segundo YEH (1985), a programação dinâmica é aplicável a problemas de planejamento e operação de reservatórios, já que esses podem ser representados em estágios seqüenciais. VOTRUBA (1988) afirma que a meta de modelos de PD para operação de reservatórios é a determinação da política de operação para todo o processo, política esta que maximize ou minimize uma função-objetivo. O processo é dividido em estágios geralmente com referência ao tempo.

Assim como a programação linear, a teoria da programação dinâmica pode ser encontrada em textos de pesquisa operacional, tais como NEMHAUSER (1966), DREYFUS e LAW (1977), SNIEDOVICH (1992) e BERTSEKAS (1995). Aplicações em sistemas de recursos hídricos podem ser encontradas em LOUCKS et al. (1981), GOODMAN (1984), VOTRUBA (1988), WURBS (1996), PORTO (1997), entre outros.

Segundo LABADIE (1987), as principais vantagens da programação dinâmica são:

- i) a possibilidade de otimização de processos dinâmicos;
- ii) a possibilidade de ter relações funcionais, tanto da função-objetivo como das restrições, extremamente não-lineares, não-convexas e até descontínuas. Isso permite representar o comportamento real do sistema, sem necessidade de aproximações (linearizações); e
- iii) ao contrário de outras técnicas matemáticas de programação, a PD produz normas de decisão retroalimentadas, o que permite tomadas de decisão em qualquer etapa do sistema.

YEH (1985) afirma que a popularidade e o sucesso da PD podem ser atribuídos à relativa facilidade de serem incluídas nos modelos características não-lineares e estocásticas, tão comuns em sistemas de recursos hídricos.

A grande desvantagem dos modelos de programação dinâmica é a dimensionalidade dos problemas. VOTRUBA (1988) mostra por meio de exemplificação, só ser possível, através das técnicas convencionais de PD, a resolução de sistemas de recursos hídricos com no máximo quatro reservatórios. LOUCKS et al. (1981) afirmam que a dimensão de um problema de PD cresce linearmente com o número de estágios, mas exponencialmente com o número de variáveis de estado (dimensão do vetor-estado). Este problema ficou conhecido como a “*maldição*” da dimensionalidade.

Nas últimas quatro décadas, diversos algoritmos têm sido criados na tentativa de superar essa “maldição”. CHOW et al. (1975) analisaram o tempo computacional e a quantidade de memória requeridos para a solução de dois algoritmos de programação dinâmica – a PD convencional ou discreta (PDD) e a PD diferencial discreta (PDDD). Eles mostram ser impossível a resolução de problemas de grande escala por meio da PD convencional, mas que é possível diminuir os esforços computacionais através da criação de novos algoritmos, como a PD diferencial discreta. Essa possibilidade e os avanços na tecnologia dos computadores digitais têm incentivado cada vez mais as pesquisas de modelos que empreguem programação dinâmica.

As linhas gerais da formulação de um problema de programação dinâmica em recursos hídricos são apresentadas a seguir. Não existe um formato padrão, pois a PD é mais uma forma de analisar um problema do que uma técnica de otimização matemática, podendo, portanto, assumir as mais variadas formas (BRAGA JR., 1983). YEH (1985) afirma que parte da arte da resolução de um problema de PD reside em encontrar a formulação mais eficiente para um problema conhecido.

A primeira etapa na formulação de um problema de PD é a definição das etapas sequenciais do problema. Para o caso típico de operação de reservatórios, essas etapas são os intervalos de tempo no horizonte operacional.

Em seguida devem ser definidas as variáveis do problema, as quais pertencerão a dois grupos: variáveis de decisão (ou controle) e variáveis de estado. As variáveis de decisão são independentes, enquanto as de estado são dependentes, tendo seus valores calculados em função das anteriores. Em problemas típicos de operação de reservatórios, as variáveis de

decisão e de estado são as retiradas e os armazenamentos em cada etapa (intervalo de tempo), respectivamente.

A terceira das etapas da PD é a definição da equação de estado para o sistema, equação essa que relaciona a variável de estado na etapa $t+1$ com as variáveis de estado e decisão para a etapa t anterior. Para operação de reservatórios, a equação de estado freqüentemente expressa o balanço de massa ou de energia do sistema em análise.

LABADIE (1987) apresenta dois requisitos para aplicação da programação dinâmica. O primeiro é que a função-objetivo seja separável, isto é, composta de funções-objetivo (ou funções de retorno) individuais para cada etapa, funções essas que sejam dependentes das variáveis de estado e/ou de decisão da etapa. Não existem restrições quanto à estrutura das funções-objetivo individuais. O segundo requisito é que as restrições sejam individuais, ou seja, cada uma delas deve estar associada com apenas uma etapa.

Entre os poucos pacotes computacionais genéricos que utilizam programação dinâmica, pode-se destacar o pacote desenvolvido por Labadie na Universidade do Colorado – EUA denominado CSUDP. Esse pacote tem sido utilizado com sucesso em diversas aplicações de PD no planejamento e no gerenciamento de problemas de recursos hídricos (WURBS, 1996). O pacote, disponível em FORTRAN e C++, permite ao usuário a criação de sub-rotinas nas quais o mesmo caracteriza a função-objetivo e as restrições do problema em análise.

Um modelo determinístico de programação dinâmica, ou um processo determinístico de decisão em múltiplos estágios (também denominado problema de controle ótimo), é caracterizado por um estado inicial x_1 e pelas funções f_t e L_t definidas como se segue. As funções f_t determinam as relações entre as variáveis de controle u_t e as de estado x_t de acordo com:

$$x_{t+1} = f_t(x_t, u_t) \quad 1 \leq t \leq N \quad (2.4)$$

As variáveis x_t e u_t são vetores reais n -dimensionais e m -dimensionais, respectivamente, onde n é o número de variáveis de estado e m o número de variáveis de controle. As funções $f_t(x, u)$ são denominadas equações dinâmicas. As funções $L_t(x, u)$ são as funções de retorno individuais para cada estágio.

Com uma seqüência $\mathbf{u} = \{u_t\}$ de variáveis de controle, seqüência essa conhecida como política operacional, pode-se definir a função de retorno para todo o processo por:

$$J(\mathbf{u}) = \sum_{t=1}^N L_t(x_t, u_t) \quad (2.5)$$

A meta do problema de controle ótimo é determinar a política de operação \mathbf{u}^* que minimize (ou maximize) a função $J(\mathbf{u})$. A política de operação ótima \mathbf{u}^* tem de estar no conjunto de políticas operacionais possíveis para o problema. Esse conjunto é definido pelas equações de restrição:

$$g_i(x_t, u_t) \leq 0, \text{ com } 1 \leq t \leq N \quad (2.6)$$

O procedimento tradicional para resolução do problema de programação dinâmica ocorre pela solução recursiva da função $V_t(x)$, denominada por BELLMAN (2003) de equação funcional. Isso se faz pela sucessiva determinação dos valores ótimos das funções $V_N(x), V_{N-1}(x), \dots, V_1(x)$, por meio da seguinte equação recursiva:

$$V_t(x) = \min(\max) [L_t(x, u) + V_{t+1}(f_t(x, u))] \quad t=N, N-1, \dots, 1 \quad (2.7)$$

onde $V_{N+1} \equiv 0$. A minimização (ou maximização) é com respeito às variáveis de controle u que satisfazem as equações (2.6). Pode-se provar que a política de operação ótima obtida, \mathbf{u}^* , é um ótimo global (YAKOWITZ, 1982).

A principal diferença entre um modelo estocástico de programação dinâmica e o modelo determinístico básico apresentado anteriormente reside nas equações dinâmicas $f_t(x, u)$. Na versão estocástica, estas são substituídas por *funções de transição probabilísticas*, $p_t(y; x, u)$, as quais para valores fixos de x, t e u são funções de densidade de probabilidade em y . Essas funções são utilizadas para especificar a distribuição de probabilidade do estado aleatório X_{t+1} se, no estágio t , o estado é x e o controle u é aplicado.

Uma “estratégia” \mathbf{S} é definida como uma seqüência de funções que, para cada estado x e estágio t , seleciona uma política de operação possível, $u_t = S_t(x)$. A estratégia \mathbf{S} tendo sido selecionada para um dado problema estocástico de controle ótimo, a lei de probabilidade para os estados X_2, \dots, X_N é unicamente determinada e o valor esperado de:

$$J(\mathbf{S}) = E\left[\sum_{t=1}^N L_t(X_t, X_{t+1}, S_t(X_t))\right] \quad (2.8)$$

é bem conhecido. A solução do problema estocástico de controle ótimo é a estratégia \mathbf{S}^* que minimiza (ou maximiza) $J(\mathbf{S})$.

O conceito de equação funcional se aplica também, com pequenas modificações, ao problema estocástico de controle ótimo. No caso estocástico, ela toma a seguinte forma:

$$V_t(x) = \min(\max) \left[\int (L_t(x, y, u) + V_{t+1}(y)) p_t(y, x, u) dy \right] \quad (2.9)$$

onde $V_{N+1}(x) = 0$ para todo x .

A formulação estocástica da programação dinâmica, em especial aquela que considera as aleatoriedades explicitamente, aumenta bastante a complexidade dos algoritmos e, conseqüentemente, o tempo de execução e a memória requeridos têm aumentos consideráveis.

2.2.3.2 – Aplicações

O primeiro algoritmo para resolução computacional do problema determinístico de PD foi apresentado por BELLMAN e DREYFUS (1962) e é hoje denominado programação dinâmica discreta (PDD). A grande dificuldade desse algoritmo é a “maldição” da dimensionalidade, já comentada anteriormente. Desde então, diversos algoritmos e aplicações, tanto determinísticos como estocásticos, têm surgido buscando principalmente a superação da “maldição” da dimensionalidade. YAKOWITZ (1982), YEH (1985), SIMINOVIC (1992) e WURBS (1996) citam uma grande quantidade destes algoritmos de programação dinâmica determinística e suas aplicações em recursos hídricos.

A primeira aplicação de um modelo de PD determinístico em operação de reservatórios ocorreu com YOUNG (1967), citado por YAKOWITZ (1982), que estudou a operação ótima para um reservatório singular com horizonte finito. ROEFS e BODIN (1970) estenderam a aplicação para o caso de múltiplos reservatórios. Nesses trabalhos, os autores utilizaram o algoritmo de PD discreta.

Os algoritmos desenvolvidos posteriormente para superar as limitações da PD discreta podem ser chamados em conjunto de métodos de aproximações sucessivas ou, na terminologia da análise numérica, de métodos iterativos (MURRAY e YAKOWITZ, 1979). Como tais, a solução ótima global pode não ser obtida, devendo-se analisar os resultados com cautela.

HEIDARI et al. (1971) propuseram um esquema computacional denominado programação dinâmica diferencial discreta (PDDD). Os autores aplicaram este algoritmo em um problema hipotético contendo quatro reservatórios. Eles mostraram que com a aplicação da PDDD obtém-se uma grande redução no esforço computacional em relação à PD discreta. Entretanto, a PDDD ainda exige um grande esforço computacional (MURRAY e

YAKOWITZ, 1979) e, sob certas condições, esta pode convergir para uma solução não-ótima (TURGEON, 1982).

LARSON (1968), citado por MURRAY e YAKOWITZ (1979), desenvolveu o método denominado programação dinâmica com estado incremental. Esse método, conhecido entre os hidrólogos por programação dinâmica de aproximação sucessiva (PDAS), foi refinado e explorado por TROTT e YEH (1973), que aplicaram a PDAS em um sistema com seis reservatórios. A vantagem deste algoritmo é que a solução do problema de dimensão seis é obtida pela da resolução de uma série de problemas unidimensionais, reduzindo consideravelmente as necessidades computacionais. A grande desvantagem da PDAS é que a convergência para um ótimo global não pode ser demonstrada genericamente. Entretanto, a convergência para um ótimo global foi demonstrada por KORSAK e LARSON (1970), citado por TROTT e YEH (1973), para três casos particulares de problemas de controle ótimo, discretos no tempo, com o número de variáveis de controle igual ao de variáveis de estado e nos quais os subproblemas possuíam apenas uma variável de estado.

Outra maneira de aliviar a “maldição” da dimensionalidade em problemas de PD determinísticos é por meio do algoritmo desenvolvido por JACOBSON e MAYNE (1970), denominado programação dinâmica diferencial (PDDif). YAKOWITZ (1989) apresenta uma visão geral do desenvolvimento deste algoritmo, permitindo uma avaliação das possibilidades de aplicação desta metodologia em problemas de tomada de decisão. MURRAY e YAKOWITZ (1979) apresentam uma modificação para a PDDif que torna esta técnica aplicável a problemas de controle de sistemas de múltiplos reservatórios. Segundo esses autores, esta metodologia é superior a todas as demais, pois não apresenta várias das limitações presentes em todas as técnicas de aproximações sucessivas existentes até então, ou seja, a PDDif: i) não sofre da “maldição” da dimensionalidade; ii) não necessita da discretização das variáveis de estado e de controle; e iii) não necessita de agrupamento de estágios. Para confirmar a aplicabilidade da metodologia em grandes sistemas de recursos hídricos, os autores apresentam sua aplicação a dois sistemas hipotéticos: um sistema com quatro reservatórios e um sistema contendo dez reservatórios.

TURGEON (1981) apresenta um algoritmo de programação dinâmica com otimização progressiva e sua aplicação a um sistema com quatro reservatórios em série. As principais vantagens deste algoritmo, segundo o autor, são: i) as variáveis de estado não precisam ser discretizadas; ii) a hipótese de convexidade da função-objetivo, necessária em técnicas de programação não-linear, não é necessária e mesmo funções descontínuas são

aceitas; e iii) ao contrário de outros métodos de aproximações sucessivas, um ótimo global é encontrado. ZESSLER (1989) utilizou esta mesma metodologia na determinação da política de operação para um sistema com oito reservatórios.

Segundo OZDEN (1984), as grandes desvantagens dos algoritmos apresentados por MURRAY e YAKOWITZ (1979) e por TURGEON (1981) são: a função-objetivo tem de ser diferenciável e as funções de restrição têm de ser lineares. OZDEN (1984) apresenta, então, um algoritmo, também baseado em PD, que supera tais desvantagens, permitindo que a função-objetivo e as funções de restrição possam ter qualquer forma. O próprio autor ressalta, entretanto, que a convergência para um ótimo global só pode ser garantida se a função-objetivo for convexa.

MOUSAVI e KARAMOUZ (2003) apresentam uma metodologia baseada em programação dinâmica determinística para melhorar o desempenho computacional da PD. Por intermédio de uma abordagem heurística, as combinações impossíveis de armazenamento nas transições de estado nos reservatórios foram eliminadas. Com esse procedimento, os autores obtiveram uma redução de 96% no tempo de processamento ao estudar um sistema composto de quatro reservatórios no Irã.

Apesar da maior complexidade dos algoritmos de PD estocástica, as primeiras aplicações na operação de reservatórios surgiram mais de uma década antes das aplicações de PD determinística, quando MASSE (1946) e LITTLE (1955) (citados por YAKOWITZ, 1982) aplicaram a PDE na operação de um reservatório singular.

YAKOWITZ (1982), YEH (1985) e SIMINOVIC (1992) apresentam vários algoritmos de PDE e suas aplicações em sistemas de recursos hídricos. YAKOWITZ (1982) afirma que, até aquela época, poucos eram os algoritmos de PDE existentes e a maioria das aplicações fazia uso da PD discreta (PDD). Algoritmos de PDD, entretanto, sofrem grande influência da dimensão dos sistemas, sendo praticamente inviável a solução de sistemas com dimensão superior a dois, principalmente se as variáveis em questão forem consideradas estocásticas. A diferença nas aplicações até aquela época residia principalmente no modelo para representação das aleatoriedades das variáveis. Sobre esse fato, este autor mostra não haver concordância entre os pesquisadores na definição do melhor modelo.

GAL (1979) apresenta um método denominado programação dinâmica estocástica paramétrica (PDEP), utilizando-o para obter uma aproximação da política ótima de operação de um sistema de três reservatórios. A eficiência desta metodologia foi comprovada pela comparação dos resultados obtidos com ela e os obtidos utilizando-se um modelo de PD

discreta. A PDEP, por diminuir os problemas com a dimensionalidade, pode ser utilizada em problemas de maior porte, mas ao contrário da PD discreta, não é totalmente automática, exigindo que o operador possua um bom conhecimento do funcionamento do sistema em análise.

Buscando políticas de operação ótimas para sistemas de múltiplos reservatórios utilizados para geração de energia hidrelétrica, TURGEON (1980) apresenta dois modelos baseados em programação dinâmica denominados método *one-at-a-time* e método agregação/decomposição. O primeiro consiste em dividir o problema original n -dimensional em n subproblemas unidimensionais em série que são resolvidos por programação dinâmica. O segundo consiste em dividir o problema original n -dimensional em n subproblemas de otimização estocástica com duas variáveis de estado (bidimensionais) que também são resolvidos por programação dinâmica. As metodologias foram aplicadas pelo autor em um sistema de seis reservatórios, tendo o segundo modelo apresentado melhores resultados.

TURGEON (1981) apresenta um modelo similar ao método agregação/decomposição, aplicando-o em um sistema de quatro reservatórios em série. Neste modelo, denominado pelo autor de método de decomposição para operação de sistemas de múltiplos reservatórios, a política de operação obtida é subótima. Tal fato, entretanto, não pode ser considerado uma grande limitação do modelo, pois, em sistemas de grande porte, é difícil encontrar uma política ótima de operação.

TREZOS e YEH (1987) apresentam o desenvolvimento de um modelo estocástico de PD diferencial (PDEDif). A PDEDif apresentada por esses autores é uma extensão do modelo determinístico de PD diferencial desenvolvido por MURRAY e YAKOWITZ (1979). Evitando a discretização das variáveis de controle e de estado, a PDEDif é uma poderosa técnica de PD, permitindo a análise de sistemas de grande porte.

TAI e GOULTER (1987) desenvolveram uma técnica heurística baseada em PD estocástica para análise da operação de três reservatórios dispostos em “Y”, ou seja, dois reservatórios em paralelo ligados em série a um terceiro reservatório à jusante. A formulação básica da PD estocástica utilizada neste modelo é a mesma apresentada para reservatório singular por LOUCKS et al. (1981). O resultado da aplicação desta metodologia mostrou-se similar ao obtido com a operação do sistema baseada em dados históricos.

FOUFOULA-GEORGIU e KITANIDIS (1988) apresentam o desenvolvimento do modelo por eles denominado programação dinâmica estocástica com gradiente (PDEG) utilizado para controle ótimo de sistemas multidimensionais de reservatórios separáveis em

estágios no tempo. Acreditam os autores que a PDEG é uma valiosa ferramenta para problemas estocásticos multidimensionais, pois, antes dela, a resolução de problemas de PD explicitamente estocástica só era possível por meio da PD discreta, que é muito influenciada pela dimensão do sistema em análise (“maldição” da dimensionalidade). Resultados da utilização da PDEG na análise de um sistema de quatro reservatórios são apresentados pelos autores. Eles afirmam, entretanto, que a PDEG não resolveu por completo o problema da otimização estocástica, sendo apenas mais um passo no desenvolvimento de algoritmos de PDE. Ressaltando que nenhum método de otimização poderá ser o melhor para todos os tipos de sistemas possíveis, os autores sugerem que pesquisas que comparem os métodos disponíveis para diversos tipos de classes de problema sejam feitas, conhecendo-se assim o método mais atrativo, em termos de precisão e eficiência computacional, para situações particulares.

MACEIRA e KELMAN (1989) apresentam um algoritmo de cálculo da política ótima de operação baseado em uma variante da programação dinâmica estocástica (PDE), chamada de programação dinâmica amostral (PDA). Este algoritmo não requer hipóteses sobre o modelo de aflúncias, trabalhando diretamente com o registro histórico de aflúncias. Foram comparados os modelos de PDE com duas alternativas para o modelo PDA: a) variável de estado de tendência hidrológica representada pela previsão de energia afluyente do estágio t até o último estágio do horizonte de planejamento, por meio do modelo de previsão de Thomas-Fiering (PDA-P1); b) idem, através do modelo de previsão PAR (p), denominado PDA-PP. Os autores concluem que a modelagem implícita do processo estocástico de aflúncias, através de cenários hidrológicos observados e com variável de estado tendência hidrológica representada pela previsão de aflúncias futuras produzidas pelo modelo PAR (p) representa uma economia de 0,4% a 6,5% quando comparado com a metodologia de PDE.

KELMAN et al. (1990) apresentam uma variação da PDE por eles denominada programação dinâmica estocástica amostral (PDEA). Ao contrário de outros algoritmos de PDE, a complexa estrutura espacial e temporal dos escoamentos não é modelada explicitamente na PDEA, e sim implicitamente capturada por um grande número de seqüências de escoamentos (amostras), observadas ou estocasticamente geradas, conhecidas como cenários de escoamento. Os autores ilustram o desempenho desta metodologia em um estudo de caso usando o sistema hidrelétrico *North Fork no Feather River* na Califórnia, obtendo melhores resultados do que os obtidos por PDE tradicional.

PICCARDI e SONCINI-SESSA (1991) apresentam modificações possíveis nos algoritmos de PDE para se tirar proveito das arquiteturas dos computadores mais modernos, permitindo soluções mais rápidas e mais precisas. Duas conclusões do trabalho desses autores valem ser ressaltadas: i) a densidade da discretização das variáveis de estado, necessária em vários algoritmos de PDE, afeta consideravelmente a solução dos problemas e ii) a hipótese de escoamentos correlacionados ou não ocasiona substanciais diferenças nos resultados da análise de sistemas reais, em que os escoamentos certamente apresentam correlações.

KARAMOUZ e VASILYADIS (1992) apresentam o modelo de PDE por eles denominado de programação dinâmica estocástica bayesiana (PDEB). Essa metodologia faz uso das técnicas de programação dinâmica e da teoria bayesiana de decisão (TBD) na obtenção de políticas de operação ótimas para sistemas de reservatórios. A incorporação da TBD em um modelo de PDE permite a constante atualização das previsões das variáveis hidrológicas, reduzindo as incertezas presentes nos modelos de previsão. Para verificar o valor da PDEB, os autores compararam seu desempenho com as performances de um modelo de PD convencional (PDE discreta) e do modelo desenvolvido por KELMAN et al. (1990), obtendo resultados satisfatórios.

VASILYADIS e KARAMOUZ (1994) apresentam uma atualização do modelo de PDEB. A diferença básica entre a nova metodologia e a PDEB é a inclusão da demanda como variável de estado, permitindo a obtenção de políticas de operação mais realistas e eficientes. Os autores afirmam que, comparando o desempenho dos dois modelos, pode-se afirmar que um modelo de otimização que considera as demandas como fixas não apresenta bons resultados quando as demandas são variáveis.

PEREIRA e CODNER (1996) apresentam um modelo de PDE visando determinar regras de operação baseadas em níveis-meta para o abastecimento urbano da cidade de Melbourne na Austrália. Níveis-Meta (ou curvas guia) de um sistema de reservatórios especificam a distribuição espacial do armazenamento entre os reservatórios do sistema.

YANG e READ (1999) desenvolveram um algoritmo de PD estocástica que apresentou bons resultados na otimização das retiradas de um sistema de dois reservatórios na Nova Zelândia.

FABER e STEDINGER (2001) apresentam um algoritmo de Programação Dinâmica Estocástica Amostral (PDEA) para otimização de reservatórios que incorpora previsões climáticas de um conjunto de hidrogramas de escoamento. Os autores utilizaram as previsões

realizadas pelo *National Weather Service (NWS)*. Segundo os autores, a possibilidade de atualização dessas previsões em tempo real permite a obtenção de decisões mais realistas do que aquelas obtidas com sofisticados modelos de PDEA, que utilizam modelos de séries temporais baseados em dados históricos.

ALVIM et al. (2003) mostram um estudo da operação otimizada do reservatório de regularização do ribeirão Serra Azul, componente do sistema que abastece a Região Metropolitana de Belo Horizonte. Os autores utilizaram com êxito a técnica de Programação Dinâmica Estocástica Markoviana (LOUCKS et al., 1981) com objetivo de maximizar a vazão aduzida para abastecimento, procurando deixar o reservatório o mais próximo possível do nível d'água (NA) ideal.

2.2.4 – A SIMULAÇÃO

2.2.4.1 – Conceitos Básicos e Aspectos Fundamentais

Simulação é uma técnica de modelagem usada para aproximar o comportamento espacial e/ou temporal de um sistema em um computador, representando suas principais características por descrições matemáticas ou algébricas. A simulação não é um procedimento de otimização como as técnicas de programação matemática discutidas anteriormente. As técnicas de programação matemática encontram, se possível, uma política de operação ótima, ou seja, uma política que minimize (ou maximize) a função de retorno para o sistema em análise, satisfazendo todas as restrições impostas. Já os modelos de simulação fornecem o valor da função de retorno para uma configuração específica do sistema submetido a uma regra de operação.

Os modelos de otimização, portanto, procuram a melhor decisão possível entre todas as alternativas, enquanto os de simulação apenas avaliam um número finito de alternativas. Isso provoca um dos maiores problemas da aplicação de modelos de simulação: a determinação do número de conjuntos de configurações e políticas de operação que devem ser simulados para que se obtenha discernimento para uma tomada de decisão. Os modelos de simulação, entretanto, são mais flexíveis e permitem uma representação mais realista do sistema, não sendo necessárias hipóteses simplificadoras na estrutura do mesmo, hipóteses essas quase sempre indispensáveis em modelos de otimização e que podem, em alguns casos, gerar políticas de operação distantes da ótima. O conceito inerente à abordagem por simulação é mais fácil de entender e comunicar do que outras abordagens, entretanto, a

busca de uma solução ótima (ou próxima da ótima) por simulação é computacionalmente exigente em termos de tempo de processamento.

A estrutura básica de um modelo de simulação para representação de um sistema de reservatórios é dada por: i) *variáveis de entrada*: constituídas pelas vazões afluentes, precipitações, evaporações e eventuais variáveis exógenas, como vazões de restrição e limites operacionais dos níveis dos reservatórios; ii) *variáveis de estado*: controlam o comportamento do sistema e variam ao longo da simulação (e.g., volume armazenado no reservatório); iii) *variáveis de saída*: respostas da simulação, escolhidas pelo responsável pela operação (e.g., custo ou benefício da operação do reservatório); iv) *parâmetros do modelo*: variáveis que caracterizam o sistema, tais como capacidade dos reservatórios; e v) *intervalo de tempo*: determinado de acordo com as necessidades do estudo, tendo em vista um balanço entre recursos computacionais e precisão dos resultados. Regras ou Políticas de operação são utilizadas em conjunto com os modelos de simulação, definindo os volumes e as defluências em cada intervalo de tempo em função de valores atuais de armazenamento e previsão de afluências.

Uma questão que gera bastante discussão na utilização de modelos de simulação é se vale a pena a utilização de pacotes computacionais genéricos ou se o analista deve desenvolver um pacote específico para o sistema a ser analisado. Segundo BRAGA JR. (1987), o melhor modelo é aquele que o analista conhece e domina. Ainda segundo esse autor, os modelos genéricos apresentam maior flexibilidade enquanto os específicos são mais rápidos e econômicos.

WURBS (1993) cita dois exemplos de modelos de simulação desenvolvidos para sistemas específicos que estão sendo utilizados com sucesso. São eles: o modelo CRSS (*Colorado River Simulation System*) e o modelo PRISM (*The Potamac River Interactive Simulation Model*). YEH (1985) afirma que, entre os pacotes computacionais genéricos de simulação, os modelos desenvolvidos pelo Centro de Engenharia Hidrológica do Corpo de Engenheiros do Exército Americano (*Hydrologic Engineering Center – HEC*) são os com melhores documentações e os que têm sido mais utilizados. Entre outros exemplos de modelos genéricos de simulação, ANDREU et al. (1991) citam o SIM-V, o MODSIM e o ARSP.

2.2.4.2 – Aplicações

Devido à simplicidade e versatilidade, modelos baseados em simulação têm sido os mais utilizados na avaliação de alternativas de sistemas de recursos hídricos. Vários autores apresentam aplicações desta técnica, entre eles LOUCKS et al. (1981), YEH (1985), BRAGA JR. (1987), VOTRUBA (1988), WURBS (1996) e EVANS e OLSON (1998).

MOLINAS e TUCCI (1989) e MOLINAS (1995) apresentam aplicações das técnicas de simulação em sistemas de reservatórios para abastecimento de água. No primeiro desses trabalhos, os autores buscaram diminuir o risco de falhas e o custo da operação para o sistema composto por dois reservatórios que abastece a cidade de Santa Maria (RS – Brasil). Os autores concluíram que a escolha apropriada das variáveis de decisão, em particular aquelas que apresentam facilidade de ser monitoradas, permite estabelecer políticas de operação que garantam o uso racional de recursos escassos. Já MOLINAS (1995) utilizou um modelo de simulação para análise do sistema de reservatórios que abastece a região metropolitana de Fortaleza (CE – Brasil), tendo como objetivos principais avaliar a real capacidade de oferta hídrica deste sistema e fornecer subsídios para uma melhor operação integrada dos reservatórios.

Apesar de os modelos de simulação terem se mostrado extremamente úteis no planejamento e na operação de sistemas de reservatórios, todos eles têm como grande desvantagem o fato de que o próprio analista tem que definir as configurações e as políticas de operação que devem ser estudadas. Sistemas mais complexos apresentarão um número grande de alternativas possíveis, dificultando a aplicação de modelos de simulação. Na busca da solução de tais problemas, a tendência das pesquisas tem sido a de incorporar esquemas de otimização em modelos de simulação, obtendo certo grau de otimização.

Duas têm sido as formas mais comuns de uso conjunto dos modelos de otimização e simulação. Na primeira, os modelos de simulação servem como técnica preliminar para delimitar espaços de soluções possíveis, espaços esses que serão pesquisados de maneira mais precisa pelos modelos de otimização para localizar o ponto de solução ótima. Na segunda, os modelos de otimização são utilizados, em sistemas com simplificações, na determinação de regras de operação, regras essas que serão em seguida processadas nos modelos de simulação em sistemas sem simplificações, verificando sua viabilidade prática e o grau de afastamento do ótimo.

JACOBY e LOUCKS (1972) utilizaram um modelo de otimização baseado em programação linear para seleccionar um conjunto preliminar de alternativas para um sistema de reservatórios na bacia do *Delaware River* (EUA). Segundo esses autores, sem a seleção preliminar de alternativas por intermédio do modelo de otimização, o número de configurações possíveis a serem simuladas inviabilizaria uma tomada de decisão que garantisse uma configuração pelo menos próxima da ótima. Já sem a possibilidade de simular os resultados do modelo de otimização, seria impossível avaliar as conseqüências das simplificações sempre presentes em modelos de otimização para sistemas complexos.

SIGVALDASON (1976) utilizou otimizações baseadas em programação linear como submodelos agregados a um modelo de simulação para determinação da política de operação de um sistema com 48 reservatórios na bacia do *Trent River* em Ontario, Canadá. No início de cada intervalo de simulação, o modelo de otimização determinava a decisão ótima (política de operação) para o período. Em seguida, o modelo de simulação utilizava esse resultado para determinar as respostas do sistema no período. O autor verificou que essa metodologia apresentou melhores resultados do que os procedimentos de decisão (e.g., regra de decisão linear) utilizados nos modelos de simulação existentes até então.

JOHNSON et al. (1991) também apresentam um modelo de simulação com otimizações a cada período de análise. A eficiência dessa metodologia foi comprovada pelos autores com a comparação das políticas operacionais obtidas por ela e as obtidas pelo modelo utilizado naquela época na operação do *Central Valley Project*, Califórnia (EUA).

KARAMOUZ e HOUCK (1982) apresentam um algoritmo que utiliza em conjunto um modelo determinístico de programação dinâmica, análises de regressão e um modelo de simulação na determinação de regras operacionais para reservatórios. Para utilização desta metodologia são necessárias duas séries de vazões contemporâneas (históricas ou geradas sinteticamente). O ciclo começa com a otimização da operação do reservatório para uma dada seqüência de vazões. Os valores ótimos obtidos são analisados por procedimentos de regressão obtendo-se regras operacionais. Essas regras são, então, testadas pelo modelo de simulação utilizando um conjunto de dados de vazão diferente do utilizado no modelo de otimização. Baseado nos resultados da simulação, verifica-se se critérios de parada previamente estabelecidos foram satisfeitos. O ciclo continua até que tais critérios sejam atendidos. Apesar de essa metodologia ser de difícil verificação teórica, 48 testes realizados pelos autores, incluindo pequenos, médios e grandes reservatórios, e diferentes características dos escoamentos (média, variância), resultaram na determinação de regras

operacionais (mensais e anuais) melhores que as obtidas com outras metodologias. Os autores afirmam que o algoritmo, desenvolvido para reservatórios isolados, pode ser facilmente estendido para sistemas complexos de múltiplos reservatórios e usos.

KARAMOUZ et al. (1992) apresentam o desenvolvimento dessa metodologia de operação em três etapas para considerar sistemas de múltiplos reservatórios. Os autores testaram a metodologia para 28 diferentes situações de um sistema com dois reservatórios, incluindo várias condições hidrológicas e pequenos, médios e grandes reservatórios. Os resultados dos testes indicaram que esta metodologia gera melhores políticas operacionais do que as normalmente utilizadas em operação de sistemas desse tipo.

CHUNG e HELWEG (1985) apresentam a aplicação de uma metodologia que utiliza simulação e otimização sequencialmente no *California State Water Project* (EUA). Os autores utilizaram o modelo HEC-3, desenvolvido pelo *Hydrologic Engineering Center* (EUA), para a simulação e um algoritmo de programação dinâmica diferencial discreta (PDDD) para a otimização. Para comprovar a utilidade da metodologia, os autores compararam a operação do sistema com esta metodologia com a operação por meio do modelo até então usado nesse sistema, o qual utilizava apenas simulação. Obtiveram benefícios duas vezes maiores com o novo algoritmo.

NANDALAL e SAKTHIVADIVEL (2002) apresentam um algoritmo que utiliza sequencialmente Programação Dinâmica Estocástica (PDE) e Simulação para o planejamento e a otimização da operação de um sistema de reservatórios no Sri Lanka. Esse sistema é utilizado tanto para geração de energia como para irrigação. Os reservatórios têm suas políticas de operação otimizadas individualmente por meio de PDE para posterior simulação do sistema completo. A aplicação desse algoritmo permitiu a redução dos déficits de água para irrigação.

Diversas outras possibilidades de combinação de modelos de simulação e otimização podem ser realizadas, sendo grande o potencial de exploração de metodologias desse tipo. Podem-se variar tanto as características da simulação (intervalo de simulação, tipo de balanço) e da otimização (tipo, nível de simplificação) como o esquema de inter-relacionamento dessas técnicas.

2.3 – AS TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

2.3.1 – LÓGICA FUZZY OU DIFUSA

Este item apresenta de forma sucinta os conceitos básicos e os aspectos fundamentais da Teoria Difusa relacionada com o objeto desta pesquisa. Livros que descrevem em detalhes a Teoria Difusa, tais como KOSKO (1992), KLIR e YUAN (1995), KASABOV (1998) e AGUIAR e OLIVEIRA JR. (1999), podem ser consultados para maiores informações.

A Teoria dos Conjuntos Difusos (TCD) é um recurso matemático usado para caracterizar e quantificar incertezas e imprecisão em dados e relações funcionais. Seu desenvolvimento formal foi iniciado por ZADEH (1965), tendo como ponto de partida a atribuição de valores intermediários para as pertinências às categorias, sendo estas representadas pelos chamados conjuntos difusos.

Enquanto nos conjuntos clássicos, a pertinência a estes pode ser considerada de forma absoluta, com graus 0 (não pertence) ou 1 (pertence), uma vez que suas fronteiras são rigorosas, nos conjuntos difusos admitem-se graus intermediários. A pertinência dos elementos a um conjunto difuso é quantificada por uma função, chamada de *função de pertinência*. Essa função descreve ambigüidade ou imprecisão, formas de incerteza diferentes de probabilidades e muito comuns em situações reais.

Pode-se, portanto, definir um conjunto difuso J como sendo um intervalo, no domínio da variável X, ao qual é associada uma função de pertinência $\mu(x)$, que representa o grau com que o elemento x pertence a J, e cujos valores podem variar de 0 a 1. As formas adotadas para as funções de pertinência são, geralmente, convexas e normais. No entanto, muitas operações sobre conjuntos difusos resultam em conjuntos que não atendem a essas características. Alguns tipos padrões para as formas das funções de pertinência têm sido utilizados, sendo a forma triangular a mais comum, seguida da trapezoidal e da sigmóide. A escolha entre estes é consequência de preferência pessoal, existência de recursos computacionais ou experimentação em busca de resultados mais favoráveis. A escolha da forma para as funções de pertinência, juntamente com a escolha do nível de quantização (número de conjuntos a utilizar para representar o espaço de domínio da variável), bem como a justaposição dos conjuntos adjacentes constituem questões subjetivas, para as quais intuição e procedimentos heurísticos têm sido utilizados.

Os Sistemas Difusos de Regras (SDR) são a aplicação mais comum da Teoria dos Conjuntos Difusos. Esses sistemas são apropriados para modelar processos cujos comportamentos são descritos de forma apenas aproximada ou por meio de regras heurísticas. Também são úteis quando a descrição do processo por modelo matemático é excessivamente complexa, de difícil representação ou utilização, podendo comprometer a confiabilidade do sistema. Nesse caso, os sistemas difusos podem contribuir significativamente, pela robustez resultante.

Nos SDR, o conhecimento existente sobre determinado tópico ou processo é descrito, armazenado e processado por intermédio de regras do tipo:

$$\text{Se } A = a \text{ e/ou } B = b \text{ então } C = c$$

onde A , B e C são variáveis que descrevem o processo; a , b e c são valores ou estados por elas assumidas. Denomina-se inferência a “avaliação” da regra, ou seja, a verificação do grau de verdade ou aplicabilidade da regra para um determinado estado do processo, definido pelos valores a , b e c . Nos SDR, as variáveis do sistema são variáveis lingüísticas ou números difusos.

A variável lingüística é a unidade básica de representação do conhecimento em inferência difusa. Nas regras, as variáveis de entrada e saída são variáveis lingüísticas. Elas assumem categorias ou valores lingüísticos, que são associados a valores determinísticos, por meio de conjuntos difusos.

Quando as variáveis do sistema não são, originalmente, descritas como conjuntos difusos, torna-se necessária a transformação do valor determinístico da variável em um valor difuso (*fuzzification*). Esse é o caso de muitas aplicações em recursos hídricos e ciências ambientais.

As regras relacionam as variáveis de entrada, ou antecedentes, com as de saída, ou conseqüentes, ou seja, relacionam o “estado atual” do processo com a “ação de controle” adequada para levá-lo ao “estado desejado” – no caso de um sistema de controle – ou com uma “conclusão” – no caso de um sistema de decisão, precisão ou diagnóstico. A escolha das regras tem como ponto de partida a análise do processo em si e a experiência dos especialistas. Um primeiro conjunto de regras obtido pode ser testado e melhorado por meio de simulações ou pela aplicação ao próprio processo real. As regras de um sistema difuso também são chamadas de memórias associativas difusas (FAM – Fuzzy Associative Memory). Quando há duas variáveis de entrada, uma matriz em duas dimensões pode

apresentar a relação entre as variáveis e o valor resultante da variável de saída para cada regra. Essa FAM pode ser imaginada no hiperespaço quando houver mais de três variáveis de entrada e/ou mais de uma de saída. Duas regras são chamadas “vizinhas” se as células correspondentes às suas saídas são contíguas em qualquer direção.

A inferência difusa é o procedimento de “avaliação” das regras que relacionam as variáveis, levando a uma conclusão final do SDR. A inferência difusa usa a lógica difusa para avaliação dos operadores lógicos utilizados nas regras. Assim, na lógica difusa, o operador E é modelado como uma interseção, por meio de normas-T, e o operador OU é modelado como uma união, por meio de normas-S. Um conjunto de regras é consolidado pela operação de união. Esse procedimento, em duas fases – a avaliação da implicação de cada regra e a composição das conclusões de todas as regras em um valor consolidado –, é também denominado Regra de Composição de Inferência – RCI. Diversas RCI têm sido propostas, cada uma com normas-T e normas-S diferentes, gerando implicações com características diferenciadas. Na maior parte dos SDR, é utilizada a inferência chamada “min-max” (“de Zadeh” ou “de Mamdani”), que usa o operador “min” como norma-T e o operador “max” como norma-S.

O conjunto difuso resultante da inferência já exprime diretamente a incerteza associada ao prognóstico. Caso seja necessário obter um valor determinístico que sintetize o seu significado, faz-se a chamada decomposição (*defuzzification*).

Segundo JANG (1993), os modelos difusos possuem os seguintes componentes: unidade de quantização (fuzificação), base de conhecimentos (banco de dados com funções de pertinência e conjunto de regras difusas), unidade de inferência difusa e unidade de desquantização (desfuzificação). A construção e a posterior operacionalização de um modelo (sistema) dessa natureza consistem, portanto, na integração ordenada desses componentes.

SCHANZER (2002) citado por ARAÚJO (2004) apresenta uma descrição detalhada das etapas de identificação de modelos difusos. As etapas descritas por esse autor são as seguintes:

- i) definição das variáveis de entrada e de saída;
- ii) fase experimental, em que se planeja e executa o experimento para aquisição do conjunto de dados de entrada-saída do sistema que será usado na construção e validação do modelo;

- iii) seleção da estrutura do modelo: seleção do tipo de modelo – lingüístico/Mamdani ou paramétrico/Takagi-Sugeno; definição do número de valores lingüísticos por variável; geração das funções de pertinência; ajuste da forma e posição das funções de pertinência; escolha do método de inferência, ou seja, do procedimento de inferência utilizado para, a partir das entradas e regras difusas, derivar o conjunto difuso de saída; definição dos operadores lógicos, ou seja, seleção dos operadores de agregação, implicação e composição; e escolha do método de desfuzificação;
- iv) geração das regras, que pode ser feita por um especialista, utilizando variáveis lingüísticas ou automaticamente com base nos dados;
- v) simplificação de regras e de funções de pertinência redundantes;
- vi) ajuste fino do modelo, realizado pelo especialista visando simplificá-lo e melhorar o desempenho; e
- vii) validação do modelo: empregando um conjunto de dados de teste diferente dos dados utilizados no treinamento do modelo.

BARBALHO (2001) afirma que o processo de modelagem baseado em regras difusas é um processo iterativo que envolve, geralmente, três etapas: identificação do modelo, treinamento ou ajuste das regras e validação do modelo. A identificação de um sistema inicial de regras é um processo subjetivo que requer, tanto quanto possível, conhecimento sobre o sistema a ser modelado. Em geral, este processo envolve as seguintes tarefas interdependentes: seleção das variáveis, partição de domínios, atribuição de funções de pertinência e termos lingüísticos e descrição das regras. O treinamento, ou ajuste de regras, é a etapa em que os parâmetros das funções de pertinência associadas aos termos lingüísticos são ajustados num conjunto de dados, denominado *conjunto de treinamento*. A validação do modelo é o processo em que se avalia o desempenho do modelo em termos de eficácia e eficiência computacional. A eficácia está relacionada com a capacidade do modelo de reproduzir as saídas desejadas quando um conjunto de dados distinto do conjunto para o qual o modelo foi treinado lhe é apresentado.

Em relação ao aprendizado, DRIANKOV et al. (1996), citado por PEDROLLO (2000), afirmam que os mecanismos de aprendizado difuso podem ser classificados em:

- ✓ **organizativos:** que atuam sobre os conjuntos difusos estabelecidos, determinando regras associativas entre estes;

- ✓ ***adaptativos***: que modificam os conjuntos, ou os pesos atribuídos às regras associativas, podendo ser realizados em conjunto com os anteriores.

O *Aprendizado Organizativo* é utilizado quando se dispõe de amostragens das variáveis que se sabe estarem relacionadas, mas se desconhecem estas relações, seja parcialmente, seja em sua totalidade. Os sistemas organizativos de aprendizado podem ser, em geral, divididos em duas fases:

- ✓ a definição da topologia do sistema (quantização das variáveis e adoção das funções de pertinência correspondentes);
- ✓ a execução da pesquisa de agrupamentos, a partir de registros amostrais.

PEDROLLO e LANNA (2003) abordam aspectos práticos do aprendizado com Sistemas baseados em Lógica Difusa (SBLD) para a modelagem hidrológica. Os autores apresentam metodologias para a superação das principais dificuldades encontradas nesse tipo de modelagem. Os dois principais fenômenos constatados pelos autores foram:

- ✓ ***Falta de Conhecimento***: que se manifesta quando o aprendizado é insuficiente, ocorrendo, posteriormente, novas situações, representadas por combinações de antecedentes, para as quais não existem regras;
- ✓ ***Falso Conhecimento***: que ocorre quando o aprendizado conduz a conjuntos de regras que descrevem perfeitamente as séries submetidas, porém não representam os fenômenos ou as relações subjacentes, o que prejudica a generalização do uso.

Esses autores apresentam uma interessante alternativa para a implementação do método organizativo. A idéia básica dos autores é a análise de agrupamentos deduzidos da amostra. A matriz cognitiva, resultante da acumulação das ocorrências das categorias da variável conseqüente para cada combinação de antecedentes, é um passo intermediário para a extração das frequências. O método apresentado soma, na matriz cognitiva, índices obtidos pela ponderação das ocorrências pelos graus de pertinência, correspondentes às conexões dos conjuntos principais, ou mais favorecidos (ou seja, com maior grau de pertinência associado), mas também índices correspondentes às conexões dos conjuntos secundários, quando estes possuem pertinência maior do que zero. Após o processamento de toda a amostra, um procedimento específico seleciona, para cada combinação ocorrida das variáveis explicativas, o conjunto mais freqüente na variável explicada, compondo uma regra associativa.

Os processos de *Aprendizado Adaptativo* implicam modificações orientadas, ou nos conjuntos difusos, ou nos pesos atribuídos a cada regra associativa. Esses processos dependem de simulações com amostras, por tentativas, para a busca da configuração ideal. O critério dos processos de busca, nos procedimentos adaptativos, é a minimização do somatório dos desvios absolutos ou dos quadráticos.

2.3.2 – REDES NEURAIS ARTIFICIAIS

Este item apresenta de forma sucinta os conceitos básicos e aspectos fundamentais das Redes Neurais Artificiais relacionados com o objeto desta pesquisa. Livros que descrevem em detalhes as RNAs, tais como KOSKO (1992), BERTSEKAS e TSITSIKLIS (1996), KASABOV (1998) e HAYKIN (2001), podem ser consultados para maiores informações.

Redes Neurais Artificiais (RNAs) são técnicas computacionais inspiradas na estrutura neural de organismos inteligentes. Como são estimadores de regressão semi-paramétricos e podem aproximar qualquer tipo de função com um grau de precisão arbitrado, as RNAs têm sido utilizadas em problemas em que a relação entre variáveis não é totalmente conhecida, em problemas de difícil modelagem, nos quais pequenas alterações nos dados de entrada não produzem grandes mudanças nos resultados, e também em problemas em que uma grande quantidade de dados esteja disponível para aprendizado ou simulação.

O neurônio artificial, ou nó neural, é um processador bastante simples. Ele pega as informações do mundo exterior ou de outros nós, toma uma única decisão sobre elas e passa o resultado, por meio de um único canal de saída, para o próximo nó neural. Quando muitos desses nós neurais são ligados para formar uma rede, o efeito combinado é a capacidade de tomar decisões complexas. O neurônio artificial é, portanto, uma estrutura lógico-matemática que procura simular a forma, o comportamento e as funções de um neurônio biológico. Assim sendo, os dendritos foram substituídos por entradas, cujas ligações com o corpo celular artificial são realizadas por meio de elementos chamados de peso (simulando as sinapses). Os estímulos captados pelas entradas são processados pela função de soma; o limiar de disparo do neurônio biológico foi substituído pela função de transferência (**Figura 2.1**).




Figura 2.1 – Representação esquemática de um Neurônio Artificial

Cada entrada é multiplicada por um peso correspondente (w_{ij}), gerando entradas ponderadas, de forma análoga à força das sinapses. Em seguida, todas essas entradas ponderadas são somadas, obtendo-se um valor que será comparado com o valor limite para ativação do neurônio. Caso esse valor alcance o valor limite de ativação do neurônio, ele se ativará; caso contrário ele ficará inativo.

A *função de ativação* antecede a *função de transferência* e tem por atribuição repassar o sinal para a saída do neurônio. A função de ativação é uma função de ordem interna, cuja atribuição é fazer acontecer um nível de ativação dentro do próprio neurônio, ou seja, é uma decisão tomada pelo neurônio sobre o que fazer com o valor resultante do somatório das entradas ponderadas. Essa decisão terá um efeito restrito ao próprio neurônio. Usualmente, a função de ativação é a própria função de soma das entradas ponderadas do neurônio. A função de transferência pode ter muitas formas. Dentre as mais utilizadas podem ser citadas as funções linear, rampa e sigmóide. A função de transferência define e envia para fora do neurônio o valor passado pela função de ativação.

Combinando diversos neurônios artificiais, forma-se o que se denomina de *Rede Neural Artificial (RNA)*. As entradas, simulando uma área de captação de estímulos, podem ser conectadas em muitos neurônios, resultando, assim, em uma série de saídas, em que cada neurônio representa uma saída. Essas conexões, em comparação com o sistema biológico, representam o contato dos dendritos com outros neurônios, formando assim as sinapses. A função da conexão em si é tornar o sinal de saída de um neurônio em um sinal de entrada de outro ou, ainda, orientar o sinal de saída para o mundo externo (mundo real). As diferentes possibilidades de conexões entre as camadas de neurônios podem gerar n números de estruturas diferentes.

As variantes de uma rede neural são muitas e, combinando-as, pode-se mudar a arquitetura conforme as características do sistema em estudo. Basicamente, os itens que compõem uma rede neural, e, portanto, estão sujeitos a modificações, são os seguintes: i) conexões entre camadas; ii) camadas intermediárias; iii) quantidade de neurônios; iv) função de transferência; e v) algoritmo de aprendizado.

Uma rede neural é especificada por sua topologia, pelas características dos nós e pelas regras de treinamento. O desempenho de um modelo de RNA depende da adequação da sua arquitetura em simular determinado problema. A arquitetura ótima é encontrada por meio de um processo de tentativa e erro, que por vezes pode levar um tempo considerável até ser encontrada. As arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior. Usualmente as camadas são classificadas em três grupos: i) *Camada de Entrada*: onde os padrões são apresentados à rede; ii) *Camadas Intermediárias* ou *Escondidas* ou *Ocultas*: onde é feita a maior parte do processamento, por intermédio das conexões ponderadas; podem ser consideradas como extratoras de características; e iii) *Camada de Saída*: onde o resultado final é concluído e apresentado (**Figura 2.2**).




Figura 2.2 – Organização em Camadas das Redes Neurais Artificiais

A camada de entrada tem esse nome apenas como figurativo, pois sua única função é armazenar a informação de entrada para ser passada para a camada seguinte de neurônios. Os elementos dessa camada normalmente possuem um nome diferente de neurônio para não serem confundidos com neurônios de processamento.

As camadas escondidas situam-se entre a camada de entrada e a camada de saída da rede neural. Não existe uma regra que defina o número de camadas escondidas, podendo variar de 0 a n camadas. Essas camadas são compostas por neurônios que possuem

exatamente a mesma estrutura que os neurônios da camada de saída. Sua única diferença é não ter contato com o mundo externo; os sinais são passados para os outros neurônios obedecendo às regras de transferência de cada neurônio. O número de neurônios da camada escondida também não obedece a nenhuma regra específica. São os neurônios das camadas escondidas que permitem que a rede detecte e capture as características relevantes nos dados, e realize um complexo mapeamento não-linear entre as variáveis de entrada e saída.

O conhecimento dos neurônios reside nos pesos sinápticos. A propriedade mais importante das redes neurais é a habilidade de aprender a partir de seu ambiente e com isso melhorar seu desempenho. Isso é feito por meio de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

O ajuste é realizado em função de um cálculo que aponta a quantidade de erro do resultado (saída). Esse ajuste procura corrigir os pesos de modo que se produza a saída desejada diante da respectiva entrada. O ajuste sináptico é resultado de um cálculo matemático. Esse cálculo visa somar ao peso atual um valor que corresponda à quantidade de erro gerada pela rede e, dessa forma, corrigir o valor do peso final.

Denomina-se algoritmo de aprendizado um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais. Esses algoritmos diferem entre si principalmente pelo modo como os pesos são modificados. Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Nesse contexto existem os seguintes paradigmas de aprendizado:

- ✓ ***Aprendizado Supervisionado***, quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada. Neste caso, o aprendizado da rede é feito com o conhecimento prévio do resultado desejado, ou seja, são fornecidos, para a rede, o conjunto de dados de entrada e as respectivas respostas. A diferença entre a resposta desejada e a atual, fornecida pela rede, é usada para calcular a correção dos pesos da rede neural;
- ✓ ***Aprendizado Não Supervisionado*** (auto-organização), quando não existe um agente externo indicando a resposta desejada para os padrões de entrada. Neste tipo de aprendizado, a rede aprende com os próprios dados de entrada (somente os estímulos de entrada são mostrados à rede), ou seja, este algoritmo não requer o conhecimento das saídas. A rede, nesse caso, é auto-organizável, isto é, ela se

organiza internamente de tal forma que cada elemento de processamento responda, estrategicamente, a um diferente conjunto de entradas.

Entre os algoritmos de aprendizado supervisionado, merece destaque o algoritmo de retropropagação de erro (*error backpropagation*), utilizado nesta pesquisa. Esse algoritmo é baseado na regra de aprendizagem por correção de erro. Consiste de dois passos através das diferentes camadas da rede: um passo para frente, a *propagação*, e um passo para trás, a *retropropagação*.

No passo para frente, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais (camada de entrada) da rede e seu efeito se propaga através da rede, camada por camada. Um conjunto de saída é produzido como a resposta real da rede. Durante o passo de propagação, os pesos sinápticos da rede são todos fixos.

Durante o passo para trás, por outro lado, os pesos sinápticos são ajustados de acordo com uma regra de correção de erro. Especificamente, a resposta real da rede é subtraída de uma resposta desejada (alvo) para produzir um sinal de erro. Esse sinal de erro é, então, propagado para trás através da rede. Os pesos sinápticos são ajustados para fazer com que a resposta da rede se mova para mais perto, em um sentido estatístico, da resposta desejada.

O objetivo do processo de treinamento é apresentar um número suficiente de pares padrões únicos de entrada e saída que, quando acoplados com uma metodologia que corrige a cada iteração os pesos interconectados, produza um conjunto final de pesos que minimize o erro global.

Toda vez que uma entrada for apresentada à rede, deverá se verificar se a saída obtida (gerada a partir dos cálculos efetuados com os pesos que a rede possui) confere com a saída desejada para aquela entrada. Se for diferente, a rede deverá ajustar os pesos de forma que armazene o conhecimento desejado. Essa iteratividade do treinamento deverá ser repetida com todo o conjunto de treinamento (entradas e saídas), a fim de que as respostas da rede estejam mais próximas das saídas desejadas.

Denomina-se ciclo ou época uma apresentação de todos os N pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. O número de ciclos ou número de épocas corresponde ao número de vezes em que os dados são apresentados à rede.

De maneira geral, o treinamento deve ser interrompido quando a rede apresentar uma boa capacidade de generalização e quando a taxa de erro for suficientemente pequena, ou

seja, menor que um erro admissível. Assim, o objetivo é encontrar um ponto ótimo de parada com erro mínimo e capacidade de generalização ótima.

A grande vantagem das RNAs na modelagem de sistemas é que elas não necessitam de uma relação física bem definida entre os dados de entrada e de saída. A desvantagem é que podem ser vistas como "caixas-pretas", nas quais quase não se sabe por que a rede chega a um determinado resultado, uma vez que os modelos não apresentam justificativas para suas respostas. Neste sentido, no entanto, pesquisas vêm sendo realizadas visando à extração de conhecimento de redes neurais artificiais, e na criação de procedimentos explicativos, onde se tenta justificar o comportamento da rede em determinadas situações.

2.3.3 – SISTEMAS NEURO-DIFUSOS

JANG (1993) propôs um tipo de modelagem que incorpora a um Sistema Especialista Difuso (SED) a estrutura de redes neurais adaptativas. A utilização desta estrutura visa permitir a transformação do conhecimento, expresso em uma *Biblioteca de Conhecimentos*, em uma base de regras do SED. É, portanto, um método para ajuste das funções de pertinência e minimização dos erros de saída, exercendo papel similar ao algoritmo de aprendizado difuso por Treinamento Organizativo. O sistema definido por JANG (1993) é denominado Sistema de Inferência Adaptativo Neuro-Difuso (ANFIS – *Adaptive Neural Fuzzy Inference System*, em inglês).

A **Figura 2.3** apresenta, de forma esquemática, a arquitetura de um ANFIS, considerando, por simplicidade de apresentação, duas variáveis de entrada (x e y) e uma de saída (z). Na arquitetura apresentada, o SED embutido no ANFIS é do tipo *Takagi-Sugeno*, opção realizada para implementação desse método nesta pesquisa. Esse tipo de SED foi proposto por TAKAGI e SUGENO (1985) e se diferencia do SED conhecido como *Método Mamdani de Inferência Difusa*, utilizado nesta pesquisa nos modelos baseados em lógica difusa, na forma de representação, no conjunto de regras, das variáveis *conseqüentes*. No modelo tipo *Takagi-Sugeno*, as funções de pertinência das variáveis *conseqüentes* são funções das variáveis de entrada e não conjuntos difusos como no modelo tipo *Mamdani*. As regras têm, portanto, a seguinte forma geral:

$$R_i: \quad \mathbf{Se} (x \acute{e} A_i) \mathbf{E} (y \acute{e} B_i) \mathbf{Ent\~{a}o} (z_i = f_i(x,y)) \quad (2.10)$$

onde x e y são variáveis difusas de entrada sobre os universos de domínio U_x e U_y , e A_i e B_i são seus possíveis valores difusos sobre os mesmos universos de domínio. Nesta pesquisa,

adotaram-se funções $f_i(x,y)$ do tipo linear afim, ou seja, $z_i = f_i(x,y) = p_i x + q_i y + r_i$, onde p_i , q_i e r_i são os parâmetros a serem ajustados.

Na **Figura 2.3**, os nós em forma de *quadrado* indicam que aquela camada é *adaptativa*, ou seja, os parâmetros das funções de ativação são ajustados durante o treinamento. Já os nós em forma de *círculo* representam unidades cujas funções de ativação são fixas, sendo a camada denominada *não-adaptativa*.

A seguir apresenta-se uma descrição sucinta de cada uma das camadas. Uma descrição mais detalhada pode ser vista em JANG (1993).

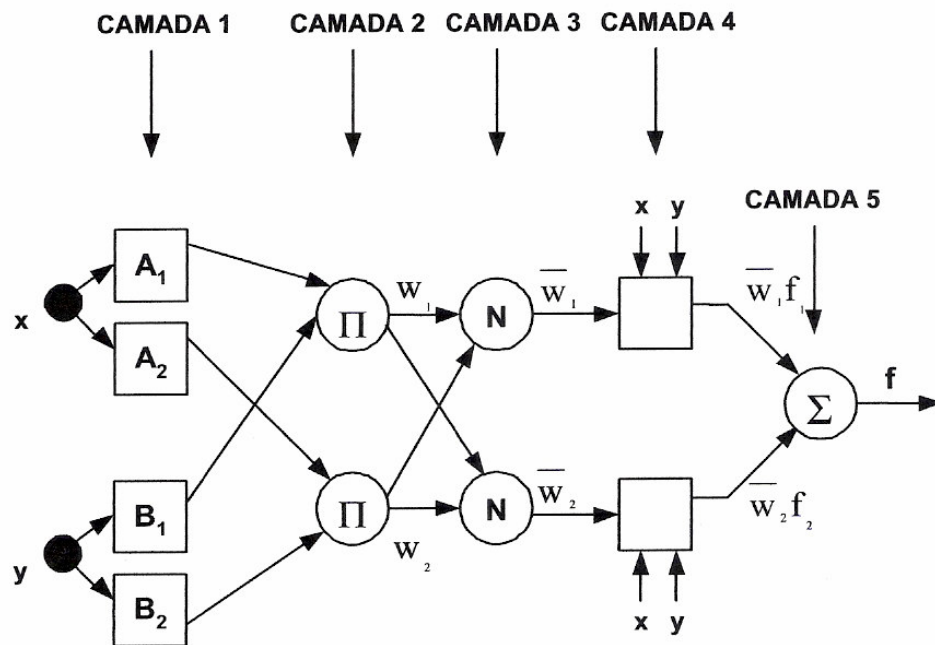


Figura 2.3 – Arquitetura do Sistema de Inferência Adaptativo Neuro-Difuso (ANFIS)

A **Camada 1** é do tipo adaptativa com função definida por:

$$O_i^1 = \mu_{A_i}(x) \quad (2.11)$$

onde x é a entrada do nó i e A_i o valor difuso lingüístico associado a esta função de nó, ou seja, O_i^1 é a função de pertinência de A_i e especifica o grau de pertinência com que a entrada x satisfaz o valor lingüístico A_i . As funções de pertinência do tipo Sino ou Gaussiana são geralmente adotadas. Os parâmetros desta camada são denominados *antecedentes*.

A **Camada 2** é do tipo não-adaptativa e, portanto, não possui parâmetros a serem ajustados. Nesta é executada uma função fixa de multiplicação dos sinais de entrada na

camada, tendo como resultado o grau de aplicabilidade (w_i) de uma regra. Matematicamente, tem-se que:

$$w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y), \quad i = 1, 2 \quad (2.12)$$

A **Camada 3** também é não-adaptativa. Nesta camada, é calculada em cada nó a razão entre a aplicabilidade da i -ésima regra (w_i) e o somatório das aplicabilidades de todo o sistema de regras. Matematicamente, tem-se:

$$\bar{w}_i = \frac{w_i}{(w_1 + w_2)}, \quad i = 1, 2 \quad (2.13)$$

onde \bar{w}_i são as saídas desta camada, denominadas *Aplicabilidades Normalizadas*.

A **Camada 4** é do tipo adaptativa com função de ativação, matematicamente representada por:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (2.14)$$

onde \bar{w}_i são as saídas da camada 3 e $\{p_i, q_i, r_i\}$ é o conjunto de parâmetros a ser ajustado. Estes parâmetros são denominados *parâmetros consequentes*.

A **Camada 5** é do tipo não-adaptativa e composta por apenas um nó que calcula a saída final, como a soma de todos os sinais de entrada oriundos da camada 4. Matematicamente, tem-se:

$$O_1^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w} \quad (2.15)$$

2.3.4 – APLICAÇÕES

2.3.4.1 – Inteligência Artificial e Recursos Hídricos

Apesar de ter seu conceito introduzido formalmente em 1965, apenas em 1985 a modelagem de sistemas baseada em lógica difusa passou a ser sistematicamente explorada com a publicação do trabalho de Takagi e Sugeno. Nesse trabalho, os autores apresentaram um modelo de regras difusas que possui grande capacidade de representação de sistemas não-lineares desconhecidos (BARBALHO, 2001). Devido às dificuldades de implementação, esse modelo manteve-se afastado das aplicações práticas. Somente quase

uma década depois, SUGENO e YASUKAWA (1993), baseando-se em técnicas de reconhecimento de padrões, desenvolveram um modelo de regras mais fácil de implementar e mais intuitivo que o modelo anterior.

Uma das primeiras aplicações da lógica difusa voltada para a área de recursos hídricos foi o trabalho de BÁRDOSSY e DUCKSTEIN (1992). Nesse trabalho, os autores propuseram um modelo difuso para apoio à decisão em um problema de recursos hídricos com múltiplos objetivos. Logo em seguida, BÁRDOSSY e DISSE (1993) desenvolveram um modelo de regras difusas para descrever o processo de percolação em zonas não saturadas do solo.

GANOULIS (1994) propôs o uso de regressão difusa para análise de incerteza e quantificação de risco em problemas de poluição em rios e águas subterrâneas e costeiras. O autor mostra que a regressão difusa pode ser útil para expressar relações funcionais entre variáveis quando a quantidade de dados é insuficiente para uma análise estatística.

SASIKUMAAR et al. (1998) desenvolveram um modelo utilizando a metodologia dos conjuntos difusos para gerenciar a qualidade da água de um sistema de rios por meio de uma abordagem de múltiplos objetivos.

YIN et al. (1999) utilizaram a metodologia fuzzy para um estudo da variação dos níveis de água na bacia do rio São Lourenço na região dos grandes lagos no Canadá. O modelo gerado utiliza a abordagem fuzzy para classificar, valorar e examinar alternativas de variação dos níveis de água.

XIONG et al. (2001) propuseram um modelo de regras difusas que permite a combinação não-linear das respostas fornecidas por diferentes modelos e mostraram que esse modelo pode representar melhor a resposta da bacia hidrográfica a uma precipitação do que qualquer modelo isoladamente e com o mesmo nível de precisão se comparado com outras combinações de modelos. Segundo os autores, os modelos de regras difusas, no entanto, são mais simples.

O uso da teoria dos conjuntos difusos em hidrologia é relativamente incipiente na literatura nacional. Exceção notável é a obra de GALVÃO e VALENÇA (1999), os quais, juntamente com outros autores, apresentam contribuições importantes sobre a teoria e a aplicação dos conjuntos difusos para modelagem, controle e análise de risco.

VIEIRA (1999) utilizou a teoria dos conjuntos difusos para o estudo de quatro casos aplicados à área de recursos hídricos. No primeiro caso, o autor determinou as relações entre

frequência e danos de cheias e entre frequência de cheias e respectivos custos de medidas de proteção. No segundo caso, foi realizada a avaliação quantitativa dos impactos ambientais da construção de um reservatório. Para o terceiro caso, o autor apresentou uma estimativa de custos ambientais a partir de estimativas realizadas por especialistas para o projeto McGree Creek em Oklahoma, Estados Unidos. Por fim, no quarto caso, para quantificar os impactos ambientais devido à construção de um reservatório no semi-árido nordestino, o autor estimou os riscos probabilísticos e difusos, bem como da influência de ações mitigadoras na redução desses riscos.

RIGHETTO e MATTOS (1999) apresentam uma metodologia para determinação das vazões de cheia de projeto em que se consideram os parâmetros do modelo como números difusos. O sistema estudado é o de macrodrenagem urbana da cidade de Franca-SP. Nesta abordagem, as vazões de projeto são especificadas por faixas de valores que quantificam as incertezas decorrentes das estimativas dos parâmetros do modelo hidrológico utilizado. Os autores utilizaram o modelo EESC para a obtenção dos hidrogramas de cheia em função das precipitações e a lógica de conjuntos difusos, por meio da inclusão de algoritmo de número difuso no modelo de transformação chuva-vazão, para a definição da faixa de incerteza de valores das vazões de projeto.

Em PEDROLLO (2000), sistemas especialistas difusos são colocados à prova para a previsão em tempo atual de níveis do rio Camaquã, pela confrontação com modelos tradicionais em uma situação em que aspectos comuns ao problema da previsão em tempo atual constituem-se em desafios a serem solucionados. Para comparação dos resultados em igualdade de condições, o autor ajustou modelos empíricos lineares para as mesmas informações utilizadas na melhor alternativa resultante da modelagem com o sistema especialista difuso. A atribuição, como consequência da aplicação de cada regra, do grau de pertinência ao conjunto difuso consequente, a partir do grau de acionamento, foi feita pelo método do mínimo. Os métodos de desquantização existentes foram comparados em função dos critérios de continuidade, plausibilidade, desambigüidade e complexidade computacional, tendo o autor optado pelo método das alturas, que se mostrou mais adequado e compatível com a regra de composição utilizada. Os resultados da pesquisa mostram que os modelos com base no sistema especialista difuso apresentam desempenhos superiores aos dos modelos empíricos lineares para previsões numéricas. O autor conclui favoravelmente à utilização dos sistemas especialistas difusos para previsão em tempo atual, tendo em conta não apenas a qualidade obtida para as previsões numéricas, mas também a capacidade de

realização de previsões sob a forma de categorias difusas. Segundo o autor, a divulgação de previsões sob forma de categorias difusas pode ser interessante, uma vez que, para problemas dessa natureza, confiabilidade é mais importante que precisão. Ao cidadão interessa saber se sua propriedade será ou não inundada, independentemente do nível exato de água previsto.

Outras aplicações de técnicas de lógica difusa em recursos hídricos (*fuzzy optimization techniques, fuzzy rule base control systems* e combinação de lógica difusa com outras técnicas) podem ser encontradas em HUANG (1996) e SAAD et al. (1996).

Revisões do estado da arte da aplicação de redes neurais em hidrologia são encontradas em ASCE (2000) e GOVINDARAJU e RAMACHANDRA (2000), demonstrando o crescente interesse pela aplicação das redes neurais em hidrologia e áreas afins, tais como modelagem do processo chuva-vazão, previsão de escoamento, modelagem de água subterrânea, previsão de precipitações e modelos de qualidade de água, entre outros.

FRENCH et al. (1992) utilizaram uma RNA para fazer a previsão do campo de intensidade de chuva no espaço e no tempo, utilizando uma rede típica de três camadas: camada de entrada, escondida e saída. O algoritmo de treinamento utilizado foi o *backpropagation*. Depois que a rede foi treinada, a RNA foi utilizada para a previsão da intensidade de chuva para uma hora.

CRESPO e MORA (1993) utilizaram uma RNA multicamadas *feedforward* para desenvolver um método de cálculo para vazões baixas a partir da precipitação, de maneira que se pudesse fazer uma melhor análise sobre o período seco. O algoritmo utilizado foi o *backpropagation*, com um ajuste *on-line*. A função de ativação utilizada foi uma tangente hiperbólica.

HSU et al. (1995) mostraram que um modelo de redes neurais não-linear representa melhor o processo de transformação chuva-vazão em uma bacia que um modelo de séries temporais tipo ARMAX (média móvel auto-regressiva com entradas exógenas). SMITH e ELI (1995) também usaram redes neurais artificiais para modelar com êxito o processo de transformação chuva-vazão. Os autores utilizaram o algoritmo *backpropagation* para prever o pico e o momento de ocorrência deste pico. ZEALAND et al. (1999) também concluíram que um modelo de redes neurais é superior a modelos tradicionais na representação das relações entrada-saída para problemas envolvendo séries temporais, particularmente em situações que não requerem a modelagem da estrutura interna da bacia hidrográfica. Resultados semelhantes também foram obtidos por VALENÇA (1999).

AQUINO et al. (1996) apresentam a aplicação de RNA no planejamento da operação de um sistema hidrotérmico. O algoritmo de RNA utilizado é o Perceptron Multicamadas (MLP), treinado pelo algoritmo de correção do erro propagado para trás (*error backpropagation*). Os resultados mostraram que a rede treinada reproduz bem os resultados objetivos para os quais foi treinada, porém não consegue generalizar bons resultados para afluições desconhecidas. Buscando melhorar a generalização da RNA para o problema, o artigo mostra uma segunda tentativa de topologia, na qual a rede inicial foi subdividida em cinco sub-redes. Essa tentativa se mostrou insuficiente para a generalização por meio da RNA. Os autores tentaram ainda mais uma topologia, considerando características físicas do problema. Mostram que há uma diminuição do erro absoluto conforme a modelagem evolui da primeira para a terceira tentativa e concluem que as RNAs tipo MLP têm capacidade de realizar com sucesso a associação de padrões e generalizar para padrões desconhecidos, inclusive com poucos dados de treinamento, desde que representativos do espaço amostral e tendo a rede sido apropriadamente modelada.

SARMENTO (1996) demonstra a possibilidade do uso da técnica de RNA na modelagem de variáveis hidrológicas mostrando duas aplicações. Conclui que as RNAs devem ser usadas na modelagem de fenômenos naturais nos casos para os quais não se dispõe de uma formulação matemática explícita, capaz de reproduzir as relações entre as diversas variáveis envolvidas. O autor afirma ainda que, para aplicações de RNA na transformação de chuva-vazão em regiões semi-áridas, a extensão da série requerida para a fase de treinamento da rede deve ser bastante superior àquelas que seriam adequadas para bacias de rios perenes.

SHAMSELDIN (1997) utilizou a técnica de RNA para fazer a modelagem da transformação chuva-vazão. O objetivo era avaliar o desempenho da técnica comparando com alguns modelos de chuva-vazão tradicionais. Foram utilizadas múltiplas entradas para apenas uma saída. A rede usada foi a multicamadas *feedforward*, por ser considerada como boa função de aproximação. A forma da rede foi testada usando diferentes tipos de informações de entrada, como, por exemplo, chuva, chuva sazonal histórica e informação do vizinho mais próximo. Com os dados de seis bacias hidrográficas, o autor aplicou a técnica para quatro diferentes cenários, onde alguns ou todos esses tipos de entrada foram utilizados. Segundo o autor, os resultados com a RNA são promissores no contexto da modelagem chuva-vazão, mas, como todos os modelos, têm resultados variáveis.

BALLINI et al. (1997) utilizaram RNA e compararam ao método de Box e Jenkins (1976) de previsão de vazões por modelos estocásticos. Os autores utilizaram dados de vazão mensal de Furnas, Itumbiara e Sobradinho. Os resultados indicam a importância da padronização das séries temporais, mostrando as vantagens dos modelos de RNA quando esta é realizada. Segundo os autores, entretanto, o desempenho das redes neurais é afetado por fatores como a topologia, os parâmetros de treinamento e a natureza das séries temporais. Os autores utilizaram o algoritmo *backpropagation* e trabalharam com duas abordagens para a previsão de vazões médias mensais. Numa primeira abordagem, a série de dados originais foi padronizada removendo a média e o desvio padrão sazonal e explorando, assim, a estrutura das funções de autocorrelação e autocorrelação parcial da série padronizada para determinar as entradas da rede. Na segunda, os autores exploraram a estrutura das funções de autocorrelação e autocorrelação parcial da série original para definir as entradas da rede. Com isso, a rede foi treinada para “aprender” e também reconhecer a sazonalidade supostamente estocástica. TANG e FISHWICK (1993) também compararam a abordagem de redes neurais em modelos de previsão de séries temporais com o método do Box-Jenkins, obtendo resultados similares.

VALENÇA (1997) fez uma análise da aplicação de redes neurais do tipo perceptron de múltiplas camadas na simulação de transformação de chuva em vazão e na previsão de vazões médias mensais. O autor concluiu que a grande vantagem da técnica de RNA está na sua versatilidade de permitir, no processo chuva-vazão, a incorporação da representatividade de cada posto pluviométrico em vez de trabalhar com chuva média. Na previsão mensal de vazão-vazão os resultados também comprovam a eficácia da técnica.

THIRUMALAI AH e DEO (1998) utilizaram RNA para modelar dados de nível de um rio. Os dados de nível são registrados num fluviômetro. Analisar e prever eventos futuros nesses registros são uma tarefa difícil, porque variáveis como chuva, infiltração e características do solo influenciam na altura do rio de uma maneira não-linear. A técnica de RNA fornece soluções de um modelo livre e apropriada para a previsão de nível. Os autores treinaram a rede usando três algoritmos: *backpropagation*, correlação cascata e gradiente conjugado, e fizeram comparação entre os resultados. Os resultados mostraram que é possível fazer previsão de nível em tempo real através das RNAs e que as boas correlações entre os valores de nível observados e os da saída da rede são encontrados independentes do algoritmo de treinamento. Concluíram, por fim, que uma rede dinamicamente adaptativa produz previsão de nível mais satisfatória que uma não adaptativa.

SPERB et al. (1999) mostram a aplicabilidade das redes neurais na previsão de enchentes pela proposição de um modelo de transformação chuva-vazão para previsão de vazões em tempo real. Devido à não-linearidade entre as variáveis, a arquitetura da rede escolhida foi a de Levenberg-Marquardt. Apesar de uma modelagem bastante simples, esta aplicação prática resultou em 93% de acerto nas previsões, o que indica serem as RNAs uma alternativa promissora para tais previsões.

KARUL et al. (2000) apresentam a aplicação de um modelo Levenberg-Marquardt de redes neurais artificiais com três camadas na modelagem do processo de eutrofização em três corpos hídricos na Turquia (reservatório Keban e os lagos Mogan e Eymir). Segundo os autores, apesar da grande complexidade e natureza peculiar do reservatório Keban, bons resultados de correlação entre valores observados e calculados (coeficientes de correlação entre 0,60 e 0,75) foram obtidos na abordagem de RNAs. Para os lagos Mogan e Eymir, que são menores e mais homogêneos, os autores obtiveram coeficientes de correlação entre valores observados e calculados em torno de 0,95. Baseados nesses resultados, os autores concluíram que as RNAs foram capazes de representar bem o comportamento não-linear dos processos de eutrofização.

DOS SANTOS (2001) descreve a utilização de uma RNA para o diagnóstico e prognóstico de vazão em bacias urbanas da Região Metropolitana de São Paulo. A autora utilizou os dados do radar meteorológico de São Paulo e os dados telemétricos da bacia do Alto Tietê. Uma RNA do tipo *feedforward* multicamadas, com aprendizado supervisionado e com o algoritmo de treinamento Linear Least Square Simplex (LLSSIM), foi aplicada. Comparou-se o desempenho da RNA com um modelo auto regressivo. A modelagem através de redes neurais demonstrou ser adequada para previsões de até 90 minutos à frente.

CHANG e CHEN (2001) propuseram uma estrutura combinada de redes neurais com sistema difuso capaz de gerar e ajustar automaticamente um modelo chuva-vazão. A estrutura utiliza um algoritmo de aprendizado híbrido. Inicialmente, um treinamento não-supervisionado é usado para agrupar as entradas em conjuntos distintos. Em seguida, os parâmetros associados com as unidades de saída são ajustados em treinamento supervisionado, buscando-se minimizar os erros entre as saídas do modelo e as saídas desejadas. Iniciando com um número de regras difusas igual a zero, geram-se automaticamente novas regras para descrever o processo hidrológico.

ROHN et al. (2003) apresentam um sistema de apoio à decisão para controle de outorgas utilizando uma solução baseada em redes neurais artificiais. A rede utilizada foi a

de retropropagação (*feedforward*) com algoritmo de aprendizagem supervisionado. Para o treinamento, foi usada a regra delta generalizada. As RNAs conseguiram identificar relações entre as características das indústrias e o consumo de água. Durante o desenvolvimento do modelo proposto pelos autores, foi testada também a análise estatística multivariada, implementando a análise de agrupamentos pela lógica difusa. Contudo, as RNAs apresentaram resultados superiores para essa aplicação.

BARATTI et al. (2003) apresentam uma abordagem baseada em redes neurais artificiais para a modelagem do processo de transformação chuva-vazão na bacia hidrográfica do rio Sardinia, na Itália. Os autores concluíram que a abordagem por meio de RNAs é uma ferramenta útil na extensão de séries temporais de vazões mensais para fins de planejamento de recursos hídricos.

TAWFIK (2003) apresenta uma comparação entre um modelo auto-regressivo (AR) e redes neurais artificiais na previsão de escoamentos no rio Nilo, no Egito. O autor conclui que a consideração pelas RNAs das não-linearidades inerentes ao processo físico permite, em alguns casos, a melhoria das previsões quando comparadas àquelas obtidas por modelos AR, sendo as RNAs uma alternativa promissora aos modelos matemáticos tradicionais de previsão.

LIMA et al. (2004) apresentam uma análise da adequabilidade dos modelos de redes neurais artificiais ao processo chuva-vazão para um clima semi-árido. Várias tipologias de modelos de RNAs foram testadas pelos autores de modo a verificar a adequabilidade do modelo e a influência de parâmetros nos ajustes. Quatro parâmetros foram tomados como definidores dos modelos de RNAs testados: número e características dos nós na camada de entrada; número de nós na camada intermediária; número de anos utilizados nas fases de treinamento e validação e função de transferência. Os testes dos modelos de RNAs foram realizados com dados de precipitação e deflúvio dos postos Icó e Podimirim, na bacia do rio Jaguaribe, no estado do Ceará. Os resultados mostraram a grande influência que tem a configuração da rede neural e o número de anos de treinamento e de validação nos resultados obtidos para previsão do deflúvio mensal na bacia hidrográfica.

MARINHO et al. (2004) mostram a comparação do modelo *Adaptive Network Based Fuzzy Inference System (ANFIS)* para realizar a previsão de vazões afluentes médias mensais um passo à frente com os modelos Periódico Auto-Regressivo (PAR), Rede Perceptron Multicamadas (MLP) e Rede Neural Nebulosa (RNN). Os resultados mostraram que o

modelo ANFIS para previsão de vazões afluentes apresentou menores erros que as outras metodologias.

Visando contrapor o principal argumento contrário ao uso de redes neurais, ou seja, o de constituírem modelos do tipo “caixa-preta”, ABRAHART et al. (1999), em análise baseada na exploração de cenários, mostraram que é possível adquirir conhecimento sobre as relações internas da arquitetura da rede.

2.3.4.2 – Lógica Difusa e Operação de Reservatórios

RUSSELL e CAMPBELL (1996) descrevem a aplicação de lógica difusa na operação de reservatórios. Segundo os autores, a lógica difusa é uma alternativa promissora, mas complementar a outras técnicas de otimização, haja vista que essa técnica é mais flexível que técnicas de regressão e permite a inclusão da opinião dos especialistas e dos operadores. Os autores destacam que a complexidade dos modelos de pesquisa operacional e a não participação dos operadores na definição e implementação desses modelos são fatores condicionantes para a pouca utilização dos resultados das pesquisas em sistemas reais. Os autores ressaltam, entretanto, que, devido à “maldição” da dimensionalidade, as técnicas de programação baseadas em lógica difusa não são, por elas mesmas, uma alternativa a outras técnicas mais convencionais. Podem ser, no entanto, técnicas complementares, proporcionando aos operadores a participação no desenvolvimento dos algoritmos de operação dos sistemas, o que permite a combinação das melhores e mais modernas técnicas de otimização com o conhecimento especializado e a experiência dos operadores.

SHRESTHA et al. (1996) demonstram a construção de uma base (regra) de decisão difusa (*fuzzy rule-based*) para a obtenção de regras operacionais para reservatório de múltiplo uso. A aplicação foi feita no Tenkiller Laker em Oklahoma. As regras operacionais foram geradas baseadas em critérios de desenvolvimento econômico e critérios ambientais. Diferentes índices de desempenho foram calculados e duas “figuras de mérito” – sustentabilidade e risco – foram desenvolvidas para analisar o modelo. Os autores concluíram o seguinte sobre modelos desta natureza: i) o modelo é muito simples; a construção ou calibração requer apenas um conjunto de treinamento que pode ser composto tanto de dados observados como advindos de modelos físicos; ii) o modelo é transparente e de fácil entendimento, devido à estrutura que reproduz a maneira humana de pensar; iii) a resposta computacional do modelo é fácil e requer pouco tempo de processamento; iv) o

modelo é robusto, ou seja, as respostas obtidas não variam significativamente com pequenas mudanças nas premissas (valores).

GALVÃO et al. (1996) apresentam um esquema de tomada de decisão para operação de reservatórios sob condições de seca. Um método para a previsão meteorológica em região tropical, para ser usado em conjunto com um modelo de transformação chuva-vazão, também foi apresentado. Os dois modelos foram construídos baseados na teoria dos sistemas difusos. O artigo discute a confiabilidade das previsões, a escolha das funções de pertinência e as regras de operação do reservatório. Os modelos foram aplicados ao reservatório Gramame-Mamuaba na Paraíba. O esquema metodológico proposto foi comparado com um esquema baseado em Programação Dinâmica Determinística (PDD). Para uma “previsão perfeita”, ou seja, simulações baseadas nos dados históricos, a PDD teve um desempenho melhor. O modelo baseado em sistemas difusos, entretanto, mostrou-se mais robusto em situações de “previsão imperfeita”. Isso provavelmente devido ao fato do modelo difuso buscar o melhor comportamento do sistema, considerando tanto os dados hidrológicos disponíveis como as características do reservatório. O modelo baseado em sistemas difusos mostrou as desejadas características de simplicidade e robustez, muito importantes em problemas em que a incerteza de futuro é parte importante da análise.

FONTANE et al. (1997) utilizaram a lógica difusa para agregar objetivos imprecisos e não mensuráveis à operação de reservatórios. Os autores desenvolveram um modelo agregando programação dinâmica e conjunto difusos, por meio da abordagem estocástica implícita. A função de pertinência difusa, para avaliar a realização de uma descrição lingüística das metas operacionais e das restrições, foi estimada com base na experiência dos decisores. A aplicação do modelo foi realizada no reservatório Grey Mountain, no Rio Cachê la Poudre, localizado ao norte do estado do Colorado. De acordo com os resultados apresentados pelos autores, o modelo forneceu um grau de satisfação de 70% para o abastecimento em seis dos 12 meses do ano e de 90% para o controle de cheia durante todo o ano. Entretanto, para os objetivos relativos a armazenamento, recreação, pesca e geração de energia, o grau de atendimento foi substancialmente baixo. Os autores observaram que a maior restrição à aplicação dessa metodologia encontra-se na condução e na análise das observações dos usuários de água e dos gerenciadores que levam ao desenvolvimento de funções de pertinência associadas aos objetivos operacionais. Os autores advertem que este processo deve ser cuidadosamente administrado e as informações corretamente interpretadas

para que se possam extrair, apenas, as informações que realmente serão úteis no processo de modelagem.

GUPTA et al. (2000) apresentam a formulação matemática de um modelo de Programação Linear Difusa multiobjetivo. O estudo de caso foi realizado na bacia do rio Narmada, na Índia. Essa bacia conta com 11 reservatórios existentes, planejados ou em construção. Os autores concluíram que a técnica adotada, apesar de simples, é eficiente para o planejamento agrícola de uma bacia com conflitos de uso e critérios de decisão não mensuráveis.

DUBROVIN et al. (2002) descrevem um modelo de controle difuso em tempo real para operação de reservatórios com múltiplos usos. O método aplicado foi o de similaridade difusa total (*total fuzzy similarity*). O desempenho deste algoritmo foi comparado com o de métodos de inferência difusa mais tradicionais, como o método de Sugeno (*Sugeno-style fuzzy inference*). Os autores concluíram que o desempenho geral do método utilizado foi bom, apesar de o modelo não conseguir captar o pensamento do especialista em circunstâncias excepcionais (extremas). Segundo os autores, essa limitação pode ser superada incluindo uma regra particular. O método apresentado mostrou resultados similares às técnicas mais tradicionais de inferência difusa. A fundamentação matemática do algoritmo adotado, no entanto, coloca a lógica difusa em bases mais sólidas. Por fim, os autores afirmam que as principais vantagens da lógica difusa são a aplicação em sentido direto (*straight-forward*) e o fato do modelo ser de fácil entendimento para os operadores devido a sua estrutura similar ao pensamento humano.

TILMANT et al. (2002a) desenvolveram um algoritmo de Programação Dinâmica Explicitamente Estocástica Difusa (PDEED). O reservatório de Mansour Eddahbi, no Marrocos, foi utilizado como estudo de caso. Pela associação da teoria difusa com um algoritmo de programação dinâmica estocástica, o algoritmo proposto por esses autores possibilita a incorporação na solução das preferências e das experiências do tomador de decisão. Isso permite considerar na obtenção de uma solução ótima, além de critérios econômicos, uma variedade de objetivos intangíveis.

CÂMARA e CORDEIRO NETTO (2003) mostram uma breve revisão da aplicação dos conjuntos difusos para o estudo e a definição de regras de operação de reservatórios. Os autores concluem que a aplicação dessa metodologia ao planejamento dos recursos hídricos permite, em tese, incorporar ao processo decisório os mais variados tipos de incerteza. Afirmam, ainda, que a forma pela qual essa técnica pode ser aplicada na operação de

reservatórios é muito variada, encontrando-se na literatura a utilização dessa teoria em conjunto com outras metodologias, tais como redes neurais, algoritmos genéticos e programação dinâmica, formando assim os denominados sistemas híbridos. Por fim, os autores concluem que a aplicação dos conjuntos difusos é vasta e útil, uma vez que essa metodologia permite agregar todas as incertezas ao processo decisório.

2.3.4.3 – Redes Neurais Artificiais e Operação de Reservatórios

SAAD et al. (1994) usaram redes neurais para a desagregação do procedimento de obtenção de políticas operacionais para sistemas hidroelétricos. RAMAN e CHANDRAMOULI (1996) descrevem a comparação de políticas operacionais para o reservatório de Tamil Nadu, na Índia, obtidas com os seguintes modelos: Programação Dinâmica (DP ou PD), Programação Dinâmica Estocástica (SDP ou PDE) e Política Padrão de Operação (SOP – Simulação). O modelo de programação dinâmica foi implementado utilizando tanto Redes Neurais (DPN ou PDN) como regressão (DPR ou PDR). As políticas operacionais obtidas pelo modelo DPN (PDN) apresentaram desempenho melhor que as obtidas pelos demais modelos. Segundo os autores, isso se deve provavelmente ao fato de que a abordagem por meio de redes neurais permite uma modelagem mais complexa do que o procedimento de regressão, representando com maior precisão a não-linearidade inerente ao sistema. Os modelos baseados em PD (PDN e PDR) tiveram desempenhos superiores aos modelos de PDE e SOP. Por fim, os autores verificaram que a maior discretização do volume dos reservatórios na implementação dos modelos proporcionou apenas melhoras marginais.

SILVA FILHO et al. (1999) descrevem a aplicação de técnicas de redes neurais na operação de plantas hidrelétricas (*hydroelectric power plants – HPP*). O comportamento ótimo dos sistemas de geração hidroelétrica depende tanto da posição relativa de cada HPP ao longo da cascata como das relações entre as HPPs. O objetivo dos autores era a aplicação de RNAs no aprendizado dessas relações, permitindo a operação ótima do sistema hidroelétrico. A arquitetura de rede utilizada foi a função de base radial (rede RBF – *Radial Basis Function*). A idéia dos autores ao utilizar redes RBF na operação de usinas hidroelétricas é fazer com que os comportamentos diferenciados que os reservatórios possuem durante a operação ótima determinística possam ser “aprendidos” pela rede e utilizados durante a operação normal do sistema, em que as afluências futuras não são conhecidas. Após aplicar em um sistema real, os autores concluíram que a metodologia é altamente promissora e estudos com sistemas de maior porte devem ser executados. Segundo

os autores, a rede RBF conseguiu assimilar o comportamento ótimo da operação do sistema teste, a ponto de apresentar um excelente desempenho durante as simulações.

A literatura mostra várias tentativas de utilização de modelos híbridos simulação-otimização para resolver com eficiência problemas de operação de reservatórios. Em muitos casos, modelos complexos de simulação estão disponíveis, mas a incorporação direta da estrutura de otimização nesses modelos é proibitiva. Para superar esta dificuldade, NEELAKANTAN e PUNDAKIKANTHAN (2000) apresentam um modelo baseado em redes neurais com algoritmo de *backpropagation* para aproximar o modelo de simulação do sistema de abastecimento da cidade de Chennai, na Índia. O modelo de RNA é utilizado como um submodelo no algoritmo de otimização não-linear com busca direta proposto por Hooke e Jeeves (1961). A estratégia dos estudos contempla cinco estágios: i) desenvolvimento de um modelo de simulação convencional e obtenção de exemplos (conjunto de dados de resultados) por intermédio de diferentes políticas operacionais; ii) treinamento, a partir dos exemplos, de uma RNA utilizando o algoritmo de *backpropagation*; iii) incorporação da RNA como submodelo do modelo de otimização não-linear por busca direta; iv) obtenção das políticas ótimas usando o modelo de simulação-otimização de redes neurais; v) refinamento das políticas operacionais por meio de modelo tradicional de simulação-otimização. Os autores concluíram que os resultados obtidos com o modelo de simulação-otimização baseado em redes neurais são satisfatórios quando comparados com modelos tradicionais de simulação-otimização. Segundo os autores, o método sugerido é uma linha de procedimento básico e flexível para utilização em diversos outros problemas.

CHANDRAMOULI e TAMAN (2001) também exploraram a possibilidade de usar redes neurais artificiais para a obtenção de regras operacionais (políticas operacionais) para sistemas de múltiplos reservatórios. Enfatizam que a combinação de simplicidade, capacidade de interpolação, capacidade para previsões estatísticas, capacidade de simulações condicionais e velocidade computacional faz das RNAs uma boa ferramenta para análise de sistemas hídricos.

CANCELLIERE et al. (2002) apresentam a aplicação de redes neurais na obtenção de regras operacionais para um sistema de irrigação. O sistema utilizado como estudo de caso foi o do reservatório Pozzillo no rio Salso, na Itália. As regras de operação foram obtidas em um processo de dois passos: i) inicialmente, a técnica de programação dinâmica, tendo a minimização do quadrado dos déficits no atendimento da demanda de irrigação

como função-objetivo, foi executada; ii) os resultados obtidos do modelo de otimização foram utilizados para o treinamento das redes neurais. A topologia de rede utilizada foi a Perceptron Multicamada, com o algoritmo de *backpropagation* para treinamento da rede. Os autores utilizaram uma combinação de modelo de balanço de umidade no solo, programação dinâmica e redes neurais para obtenção das regras operacionais. Os resultados foram analisados pela comparação, via processo de simulação, de diferentes regras operacionais, incluindo a regra Política Operacional Padrão (*Standard Operating Policy – SOP*), que se caracteriza pelo atendimento da demanda sempre que possível. As regras operacionais também foram comparadas por meio do cálculo de índices de desempenho. Os autores concluíram que os resultados obtidos com a aplicação das redes neurais foram satisfatórios tanto para períodos normais como para períodos secos.

CANCELLIERE et al. (2003) apresentam uma metodologia baseada em técnicas de otimização e de redes neurais para a obtenção de políticas operacionais para um sistema de reservatórios de múltiplo uso. Para estabelecer regras operacionais capazes de enfrentar secas de diferentes intensidades, vários cenários de disponibilidade foram hipotetizados pelos autores. O método de otimização multiobjetivo da restrição ϵ (*ϵ -constraints*) foi usado para obter uma solução não dominante que represente o *trade-off* entre dois objetivos conflitantes. Depois as RNAs foram treinadas para os resultados da otimização. A arquitetura de RNA utilizada foi a de Perceptron Multicamada. O treinamento/ calibração foi feito por meio do algoritmo de Levenberg-Marquardt que minimiza uma função de erro na rede. A base deste algoritmo é uma expansão por Série de Taylor da função de erro do ponto atual, negligenciando termos de ordem superior a 2. O algoritmo de Levenberg-Marquardt é uma modificação do algoritmo de Newton. O sistema estudado inclui o reservatório Pozzilo, utilizado para fins de irrigação, no rio Salso, tributário do Rio Simeto, principal curso d'água da Sicília, na Itália, e o reservatório Ancipa, utilizado para fins de abastecimento humano. A eficácia do sistema foi verificada por meio da operação para períodos secos, normais e chuvosos baseada em índices de desempenho. Os resultados mostraram que as regras operacionais obtidas comportam-se bem para diferentes cenários hidrológicos e podem ser usadas com eficácia para operação ótima de curto-prazo.

2.3.4.4 – Sistemas Neuro-Difusos e Operação de Reservatórios

GIULIANO et al. (2003) apresentam a implementação de uma metodologia para obtenção de regras de operação para sistemas de reservatórios de múltiplos usos pela aplicação de otimização e sistema híbrido neuro-difuso. A técnica implementada é uma

modificação da técnica de *Adaptive-Network based Fuzzy Inference Systems* (ANFIS), combinada com um método de otimização multiobjetivo que permite a derivação de regras operacionais.

A técnica ANFIS permite definir os parâmetros da função de pertinência que melhor associam um sistema de inferência difusa aos dados de entrada/saída. Embora a técnica ANFIS possa ser aplicada com sucesso em sistemas para os quais se tem um bom conjunto de dados de entrada/saída, a principal vantagem dos sistemas tradicionais, ou seja, a possibilidade de construção de regras a partir da experiência, é parcialmente perdida, embora as regras obtidas possam ser ajustadas *a posteriori*. Segundo os autores, a adaptação feita por eles permitiu a preservação das principais vantagens dos sistemas de inferência difusa.

2.4 – COMPARAÇÃO ENTRE TÉCNICAS TRADICIONAIS E BASEADAS EM INTELIGÊNCIA ARTIFICIAL

Poucos são os relatos na literatura científica de pesquisas na área de recursos hídricos sobre comparação entre as técnicas ditas tradicionais e aquelas baseadas em sistemas inteligentes. A seguir são apresentados alguns destes relatos.

YU e YANG (2000) apresentam um algoritmo baseado em lógica difusa para calibração dos parâmetros de modelo de transformação chuva-vazão. O modelo proposto tem seu desempenho comparado com outros modelos baseados nas funções-objetivo *root mean square error* (RMSE) e *mean absolute percent error* (MPE). Os autores destacam que o modelo baseado em lógica difusa não só foi capaz de melhorar os resultados como também passou a permitir aos usuários do modelo especificar o grau de aceitabilidade de cada estação de medição para diferentes campos de aplicação.

AZEVEDO et al. (2004) apresentam uma tentativa de comparação entre modelos hidrológicos utilizando Redes Neurais Artificiais (modelo Qnet) e o programa computacional desenvolvido pelo professor José Roberto Gonçalves de Azevedo em sua tese de doutorado por Regressão Linear Simples (modelo SFModel). As simulações realizadas por meio do modelo Qnet apresentaram coeficientes de determinação, em sua maioria, mais elevados que os obtidos com o SFModel. Apesar das vantagens encontradas na utilização de RNA, os autores recomendam alguns cuidados especiais em seu emprego, em especial quanto à representatividade física dos resultados obtidos.

LIMA et al (2005) apresentam a comparação, para modelagem de processos chuva-vazão, de modelos baseados em redes neurais artificiais com um modelo hidrológico

conceitual (MODHAC). Pela aplicação no semi-árido cearense, os autores mostraram a superioridade da modelagem por RNAs sobre a conceitual.

Especificamente na operação de reservatórios, GALVÃO et al. (1996) apresentam a comparação de modelos baseados na teoria dos sistemas difusos com um esquema baseado em Programação Dinâmica Determinística (PDD), considerando, nos dois casos, previsão climática. Na aplicação ao reservatório Gramame-Mamuaba na Paraíba, a PDD teve um desempenho superior para uma “previsão perfeita”, ou seja, simulações baseadas nos dados históricos. O modelo baseado em sistemas difusos, entretanto, mostrou-se mais robusto em situações de “previsão imperfeita”.

SUHARYANTO et al. (1996?) apresentam a comparação entre modelos de programação dinâmica estocástica tradicional (PDE) e de programação dinâmica difusa estocástica (PDDE) na obtenção de políticas operacionais para o reservatório Fairbairn, na Austrália. Considerando diversas variações do modelo difuso, os autores concluíram que a operação do reservatório por meio da PDE mostrou índices de desempenho inferiores aos de todos os modelos de PDDE testados.

GOULTER e SUHARYANTO (1996?) mostram que a Programação Dinâmica Estocástica Difusa (PDED ou SFFP), utilizando tanto uma função de pertinência triangular como trapezoidal para os intervalos de armazenamento, é capaz de identificar um melhor “caminho” ótimo e, portanto, melhorar as políticas operacionais de reservatórios quando comparadas com aquelas obtidas pela programação dinâmica tradicional. Em uma comparação entre as técnicas de PDED, os resultados mostram que os erros obtidos são menores quando se utiliza a função de pertinência trapezoidal.

TILMANT et al. (2002b) comparam a obtenção de políticas operacionais de reservatórios por meio de lógica difusa e não-difusa. Os algoritmos utilizados na comparação foram: Programação Dinâmica Estocástica Tradicional (PDE) e Programação Dinâmica Estocástica Difusa (PDED). Nessa investigação, os autores procuraram: i) desmistificar a abordagem difusa, mostrando que as decisões de retiradas são quase idênticas às obtidas com formulações tradicionais não-difusas; ii) mostrar que pela abordagem difusa os objetivos não-econômicos podem ser considerados de uma forma mais natural do que nas abordagens tradicionais; e iii) mostrar que a formulação difusa é uma alternativa viável para as técnicas tradicionais. Os autores concluem que com o mesmo esquema de discretização e a mesma informação hidrológica, os dois modelos geraram resultados similares. Enfatizam que o objetivo do artigo não é demonstrar qual a melhor técnica, já que a escolha da mesma deverá

ser específica para cada caso particular; cada técnica terá suas vantagens e desvantagens. A principal vantagem da técnica que utiliza lógica difusa é sua habilidade de capturar explicitamente as preferências dos usuários e dos operadores.

CHANDRAMOULI e TAMAN (2001) discutem a utilização de uma combinação de PD e RNA para múltiplos reservatórios. Um algoritmo de programação dinâmica determinística foi utilizado para operar um sistema com três reservatórios. A partir dos resultados da otimização, RNAs foram treinadas, utilizando o algoritmo de *backpropagation*, para obtenção de regras operacionais. O desempenho desse sistema foi comparado com resultados obtidos por modelos de programação dinâmica cujas regras operacionais foram encontradas por regressão múltipla. Os autores concluíram que o modelo proposto por eles teve um desempenho superior ao modelo de PD com regras operacionais obtidas por regressão.

CAPÍTULO 3 – MATERIAIS E MÉTODOS

3 – MATERIAIS E MÉTODOS

3.1 – INTRODUÇÃO

A análise da viabilidade do uso de sistemas inteligentes, particularmente aqueles baseados em lógica difusa (LD), em redes neurais artificiais (RNA) e os sistemas híbridos neuro-difusos, como ferramentas alternativas para a modelagem de sistemas complexos de reservatórios e para a obtenção das respectivas políticas operacionais ótimas, constitui-se no principal objetivo dos testes realizados nesta pesquisa. Tendo em vista que o uso das técnicas de Inteligência Artificial (IA) em operação de sistemas de reservatórios é uma alternativa recente, um período de aperfeiçoamento de recursos e forma de utilização é esperado. Deseja-se analisar nesta pesquisa, no entanto, se o desenvolvimento até então, é suficiente para afirmar que a qualidade das políticas operacionais obtidas é superior, ou pelos menos igual, àquelas obtidas por recursos tradicionais.

Nas modelagens utilizadas, procedimentos específicos foram estabelecidos com base na análise teórica e na preferência pessoal. A experimentação de outras hipóteses é desejável. Considera-se, no entanto, mais importante neste momento e nesta pesquisa, a análise, pela confrontação tanto com recursos tradicionais como entre os sistemas inteligentes propostos, da viabilidade das técnicas aqui adotadas para operação de reservatórios.

As abordagens utilizadas, seja na estrutura de combinação entre as técnicas seja nos testes realizados, incorporam diversos aperfeiçoamentos às pesquisas descritas na literatura mais recente, permitindo, por intermédio da experimentação em um sistema real complexo, a verificação, a consolidação e a ampliação do conhecimento existente sobre os sistemas inteligentes no processo de tomada de decisão na operação de reservatórios.

As informações necessárias, tanto em termos de dados como de metodologias, para obtenção dos objetivos da tese são descritas neste capítulo. Para melhor compreensão, o mesmo está dividido em quatro partes, incluindo esta breve introdução. No item 3.2, a estrutura física do sistema utilizado para o teste das metodologias propostas é descrita e os dados básicos necessários à modelagem são apresentados. No item 3.3, são apresentadas as metodologias específicas utilizadas nesta tese, quais sejam:

- i) a técnica de otimização – Programação Dinâmica Incremental – utilizada para geração da Biblioteca (Bases) de Conhecimentos que serviu de ponto de partida

para a obtenção das políticas operacionais tanto através das abordagens tradicionais como através de técnicas baseadas em Inteligência Artificial. A escolha da programação dinâmica para este fim se deve a possibilidade, através desta técnica, de otimização de processos dinâmicos e de inclusão de relações funcionais não-lineares, tanto na função-objetivo como nas restrições.

- ii) a técnica (modelo) de simulação utilizada na comparação de desempenho entre as diversas técnicas. Apresenta-se, também, uma Política Operacional Heurística (POH) cujo desempenho foi comparado com as Políticas Operacionais (PO) obtidas através de outras técnicas.
- iii) as abordagens tradicionais de obtenção de políticas operacionais utilizadas nesta pesquisa – análise de regressão e zoneamento dos reservatórios.
- iv) as metodologias baseadas em Inteligência Artificial (IA).

Por fim, a estrutura e os subsídios para análise são apresentados no item 3.4.

3.2 – SISTEMA DE RESERVATÓRIOS PARA ANÁLISE

3.2.1 – DESCRIÇÃO FÍSICA DO SISTEMA

O sistema escolhido para análise é o que abastece atualmente a Região Metropolitana de Fortaleza (RMF). Esse é composto por cinco reservatórios (Pacoti, Riachão e Acarape do Meio, na bacia do rio Pacoti; Pacajus, na bacia do rio Choró; e Gavião, na bacia do rio Cocó) interligados por canais, túneis e adutoras. Este sistema é complementado por águas advindas da bacia do rio Jaguaribe no sul do estado do Ceará. A transposição das águas da bacia do rio Jaguaribe para o sistema da RMF é feita através do Canal do Trabalhador, que capta água em uma barragem de derivação no município de Itaiçaba. Está em construção um segundo eixo de integração das águas entre a bacia do Jaguaribe e a RMF, com captação direta no açude Castanhão, localizado no médio curso do rio Jaguaribe. Tendo em vista que o início da operação desse segundo canal é ainda imprevisível e que o sistema atual apresenta-se com complexidade suficiente para os testes pretendidos nesta pesquisa, esse segundo eixo está sendo desconsiderado nas análises, sendo sua inclusão objeto de investigações futuras. A **Figura 3.1a** mostra a representação esquemática do sistema. Para facilitar a compreensão, a **Figura 3.1b** apresenta o diagrama unifilar deste mesmo sistema.



Fonte: COGERH – Companhia de Gestão de Recursos Hídricos do Ceará

Figura 3.1a – Representação Esquemática do Sistema Integrado de Abastecimento da Região Metropolitana de Fortaleza (RMF)

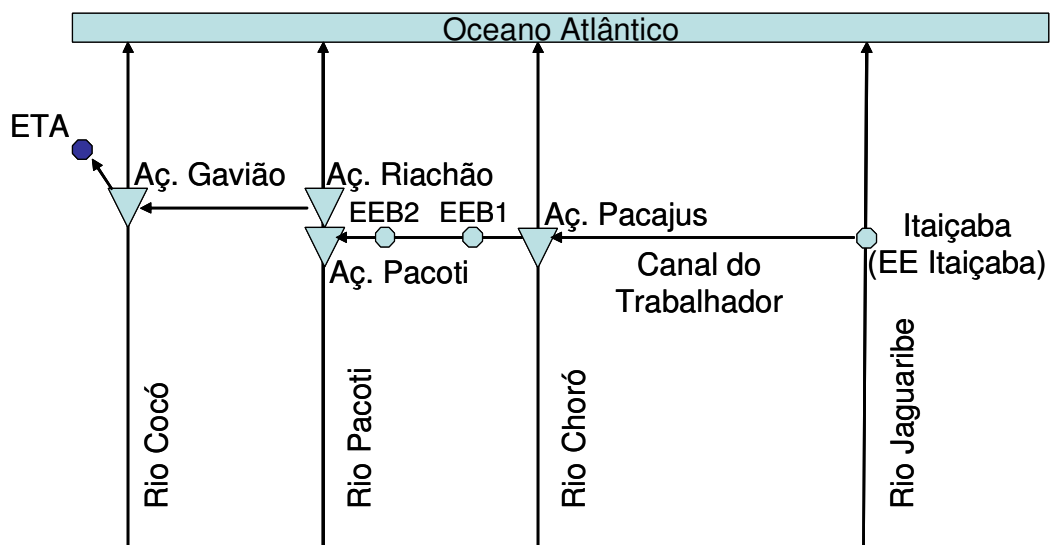


Figura 3.1b – Diagrama Unifilar do Sistema utilizado no Estudo de Caso.

O maior reservatório é o Pacoti, formado pelo barramento do rio de mesmo nome. Possui uma capacidade de acumulação de 370 hm^3 e uma bacia hidráulica de $25 \times 10^6 \text{ m}^2$. Um canal a céu aberto, escavado em terra e rocha, de forma irregular, faz a ligação desse reservatório ao açude Riachão, permitindo ao conjunto um funcionamento em vasos comunicantes até um determinado nível de água. O açude Riachão tem uma capacidade de acumulação de 87 hm^3 e bacia hidráulica de $6 \times 10^6 \text{ m}^2$. Os dois reservatórios (Pacoti e Riachão) têm um vertedouro único em labirinto.

Um canal de acesso, um túnel escavado em rocha controlado por comportas e um segundo canal adutor ligam os reservatórios Riachão e Gavião. Deste último a água é captada para a ETA – Gavião. O túnel é tipo ferradura, revestido com concreto simples, com vazão de projeto de $9 \text{ m}^3/\text{s}$. Os canais de acesso e fuga têm como finalidade encaminhar as águas do açude Riachão para o túnel e levá-las depois até o açude Gavião, não sendo limitantes para a vazão no túnel. O açude Gavião, formado por uma barragem no rio Cocó, tem capacidade de acumulação de 54 hm^3 e bacia hidráulica de $9,2 \times 10^6 \text{ m}^2$.

O açude Acarape do Meio, que também barra o rio Pacoti, à montante do açude Pacoti, tem uma capacidade de acumulação de 34 hm^3 e bacia hidráulica de $2,3 \times 10^6 \text{ m}^2$. Através da adutora do Acarape, abastece com água bruta, independentemente do sistema global, o Distrito Industrial de Maracanaú e os municípios de Guaiúba, Pacatuba e Maranguape. Através da adutora de Redenção, abastece com água tratada, na ETA – Pici, os municípios de Redenção, Acarape, Barreiras e Antônio Diogo. Pode, ainda, liberar água no leito do rio Pacoti através da tomada d'água, alimentando, assim, o sistema de abastecimento principal.

O açude Pacajus, que barra o rio Choró, tem uma capacidade de 148 hm^3 e uma bacia hidráulica de $31,7 \times 10^6 \text{ m}^2$. Apresenta um vertedouro tipo labirinto com largura de 352 m. O Canal do Trabalhador, com uma vazão máxima de projeto de $6 \text{ m}^3/\text{s}$, tem uma extensão de 102 km entre a captação, no município de Itaiçaba, e o açude Pacajus. No ponto de captação, o rio Jaguaribe está alimentado pelas águas dos açudes Orós, Castanhão, Banabuiú e Pedra Branca, que podem regularizar uma vazão total de cerca de $60 \text{ m}^3/\text{s}$.

No percurso da água de Itaiçaba ao açude Pacoti existem três estações elevatórias. As principais características destas estações estão na **Tabela 3.1** a seguir.

Tabela 3.1 – Características das Estações Elevatórias

Estação Elevatória	Qte. de bombas	Potência	Altura Manométrica	Vazão do Conjunto
EE Itaiçaba	6 (uma reserva)	1000 CV cada	48 m	6 m ³ /s
EE Ererê (EEB1)	4 (uma reserva)	450 CV cada	12,5 m	5 m ³ /s
EE Pacajus (EEB2)	4 (uma reserva)	800 CV cada	25,7 m	5 m ³ /s

Fonte: CAGECE – Companhia de Água e Esgoto de Estado do Ceará

A ligação entre o açude Pacajus, que recebe a água do Canal do Trabalhador, e o açude Pacoti é realizada através de três canais. O primeiro, denominado canal de ligação Pacajus/Ererê, tem por finalidade conduzir a água do açude Pacajus até a EE Ererê (EEB1). É uma seção escavada ao longo do leito do riacho Ererê com comprimento de 2.443 m e vazão de projeto de 13,60 m³/s. O segundo canal, denominado canal de ligação Ererê/EE Pacajus, tem por finalidade levar a água do açude Ererê até a EE Pacajus (EEB2). O reservatório Ererê funciona apenas como uma caixa de passagem, não tendo função de armazenamento no sistema da RMF. O canal tem um comprimento de 3.250 m e vazão de projeto de 5,10 m³/s. O terceiro canal, que complementa a ligação entre os reservatórios Pacajus e Pacoti, faz a ligação da EE Pacajus com o açude Pacoti. A vazão de projeto desse canal também é de 5,10 m³/s.

3.2.2 – DADOS BÁSICOS

Segundo Yeh (1982), citado BRAGA JR. (1987), as variáveis de entrada necessárias para um modelo de operação de sistemas de reservatórios são as precipitações e as evaporações sobre os espelhos d'água, as vazões afluentes e eventuais variáveis exógenas, como vazões de restrição, limites operacionais dos níveis dos reservatórios, vazões oriundas de transposição entre bacias hidrográficas, entre outras.

Seguindo essa orientação, apresenta-se neste item uma compilação dos dados necessários para o caso em estudo, quais sejam: as médias mensais das precipitações, das evaporações e das evapotranspirações sobre os espelhos d'água e as séries de vazões afluentes, calculadas pelo modelo chuva x deflúvio MODHAC (LANNA e SCHWAZEBACH, 1989) para os reservatórios do sistema. Além dessas informações, são apresentadas as curvas Cota x Área x Volume dos reservatórios que compõem o sistema.

A melhor forma de obter-se discernimento sobre a precipitação, evaporação e evapotranspiração é por meio de seus valores médios. As **Figuras 3.2 a 3.4** a seguir mostram o comportamento dessas variáveis para os reservatórios Gavião, Pacoti/Riachão e Pacajus, respectivamente. É importante frisar que no caso específico da precipitação no estado do Ceará, há grandes variações interanuais (observe-se nas figuras as diferenças entre os valores para *Anos Secos*, *Anos Normais* e *Anos Chuvosos*), tendo-se que se fazer uso do coeficiente de variação da mesma para melhor caracterizá-la.

Nesta pesquisa, como só se considera na equação do balanço aquela precipitação sobre o espelho d'água, é aceitável a hipótese de utilização da média para todos os anos da série existente. Ressalte-se, entretanto, que na utilização do MODHAC foram consideradas as variações interanuais das precipitações e, por conseguinte, as vazões afluentes aos reservatórios levam em consideração esse importante fator.

As séries de vazões afluentes aos reservatórios em estudo foram obtidas através da utilização dos valores históricos observados e do modelo chuva \times deflúvio MODHAC. Escolheu-se o MODHAC por já ter sido este utilizado com sucesso em vários estudos no estado do Ceará. Os valores históricos de vazão foram utilizados na calibração do MODHAC. Depois de calibrado, e utilizando como dados de entrada os valores precipitados, o MODHAC foi utilizado na extensão das séries de deflúvio.

As **Figuras 3.5 a 3.7** a seguir mostram as séries de deflúvios geradas para os reservatórios do Gavião, Pacoti/Riachão e Pacajus, respectivamente. As linhas verticais nas três figuras indicam períodos de 5 anos. Vale observar a grande variabilidade, em todos os reservatórios, que existe inter-anualmente, o que dificulta a definição de uma regra de operação para o sistema. Essa característica é o principal fator condicionante tanto no dimensionamento quanto na operação de sistemas de reservatórios em regiões como o semi-árido cearense.

Qualquer que seja o modelo de operação que se utilize em um sistema de reservatórios, necessário se faz o conhecimento das relações entre as cotas, as áreas e os volumes dos mesmos. As **Figuras 3.8 a 3.10** mostram estas relações para os açudes Gavião, Pacoti/Riachão e Pacajus, respectivamente.

Reservatório Gavião - Precipitação				
Meses	Ano Seco	Ano Normal	Ano Chuvoso	Média
	1983	1976	1974	
Jan	32,3	84,3	438,7	99,3
Fev	173,1	374,8	232,1	189,8
Mar	236,4	296,0	505,8	300,8
Abr	60,0	332,6	767,7	291,5
Mai	54,4	66,2	511,0	181,9
Jun	9,7	29,0	164,9	92,7
Jul	0,6	10,7	27,6	39,6
Ago	0,9	7,5	22,1	15,6
Set	0,2	0,0	39,4	12,9
Out	3,9	99,0	37,5	12,1
Nov	0,1	22,6	22,3	15,4
Dez	12,2	6,7	123,4	46,2
Total	583,8	1329,4	2892,5	1297,7

Reservatório Gavião - Evapotranspiração e Evaporação		
Meses	Evapotranspiração Média na Bacia	Evaporação Média no Reservatório
	Jan	120,5
Fev	99,5	92,7
Mar	100,5	72,3
Abr	88,0	62,9
Mai	88,0	72,3
Jun	84,5	80,8
Jul	99,0	104,6
Ago	113,5	147,1
Set	121,5	164,1
Out	131,5	167,5
Nov	125,0	157,3
Dez	124,5	153,9
Total	1296,0	1402,2





Figura 3.2 – Distribuição Temporal de Variáveis Climatológicas na Bacia do Açude Gavião

Reservatórios Pacoti/Riachão - Precipitação				
Meses	Ano Seco	Ano Normal	Ano Chuvoso	Média
	1983	1976	1974	
Jan	11,1	65,7	394,9	88,4
Fev	176,7	234,2	219,9	163,9
Mar	197,8	280,0	433,1	266,5
Abr	89,1	257,2	499,4	255,0
Mai	64,1	46,2	326,0	161,2
Jun	20,0	29,3	107,3	76,7
Jul	4,9	33,8	33,3	33,6
Ago	3,4	15,4	22,6	11,7
Set	1,3	6,5	34,3	9,6
Out	11,5	64,1	13,3	9,8
Nov	1,4	17,7	9,0	11,7
Dez	17,7	6,1	91,8	37,9
Total	599,0	1056,2	2184,9	1126,0

Reservatórios Pacoti/Riachão - Evapotranspiração e Evaporação		
Meses	Evapotranspiração Média na Bacia	Evaporação Média no Reservatório
	Jan	120,5
Fev	99,5	92,7
Mar	100,5	72,3
Abr	88,0	62,9
Mai	88,0	72,3
Jun	84,5	80,8
Jul	99,0	104,6
Ago	113,5	147,1
Set	121,5	164,1
Out	131,5	167,5
Nov	125,0	157,3
Dez	124,5	153,9
Total	1296,0	1402,2


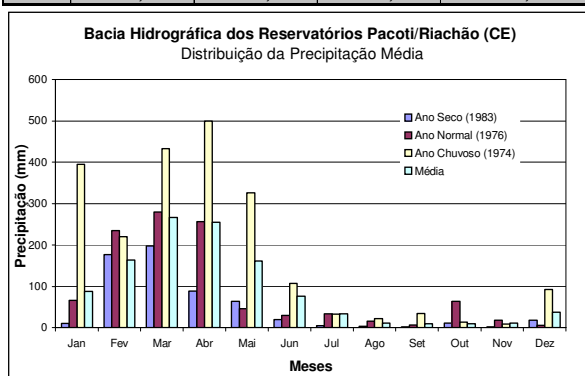


Figura 3.3 – Distribuição Temporal de Variáveis Climatológicas nas Bacias dos Açudes Pacoti e Riachão

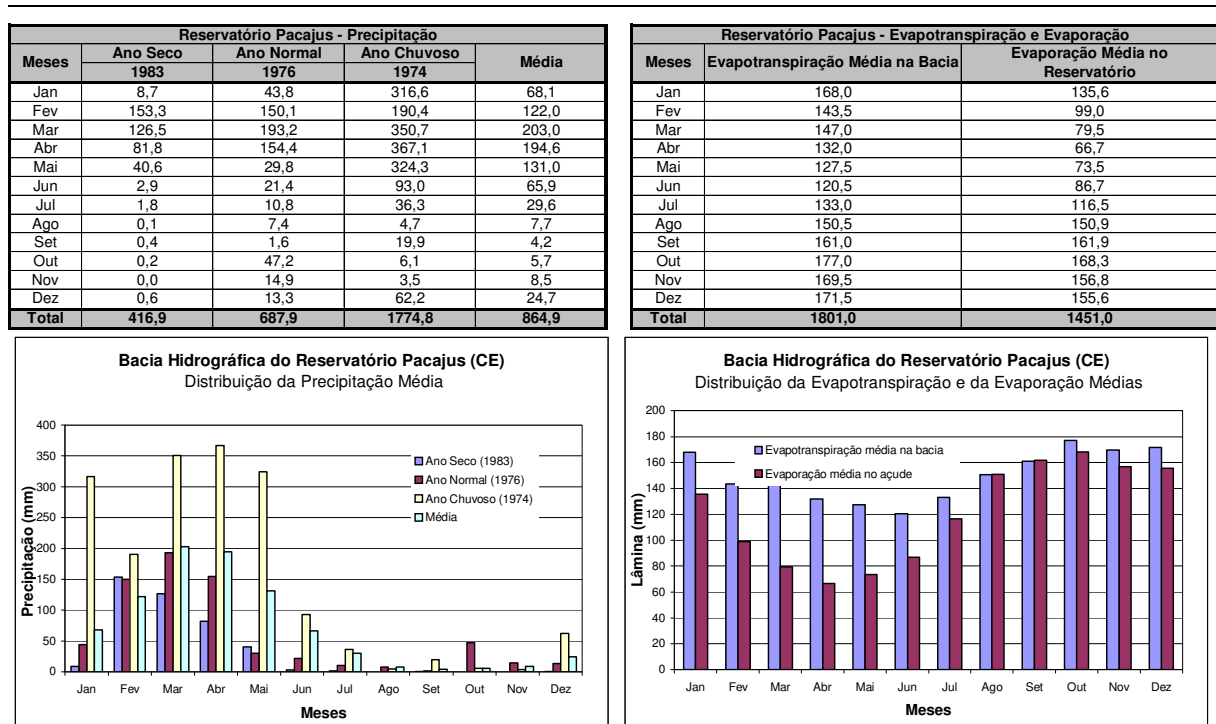


Figura 3.4 – Distribuição Temporal de Variáveis Climatológicas na Bacia do Açude Pacajus




Figura 3.5 – Deflúvios Afluentes ao Reservatório Gavião (1912 a 1996)

Série de Deflúvios Afluentes aos Reservatórios Pacoti/Riachão (1912 a 1996)




Figura 3.6 – Deflúvios Afluentes aos Reservatórios Pacoti/Riachão (1912 a 1996)

Série de Deflúvios Afluentes ao Reservatório Pacajus (1912 a 1996)

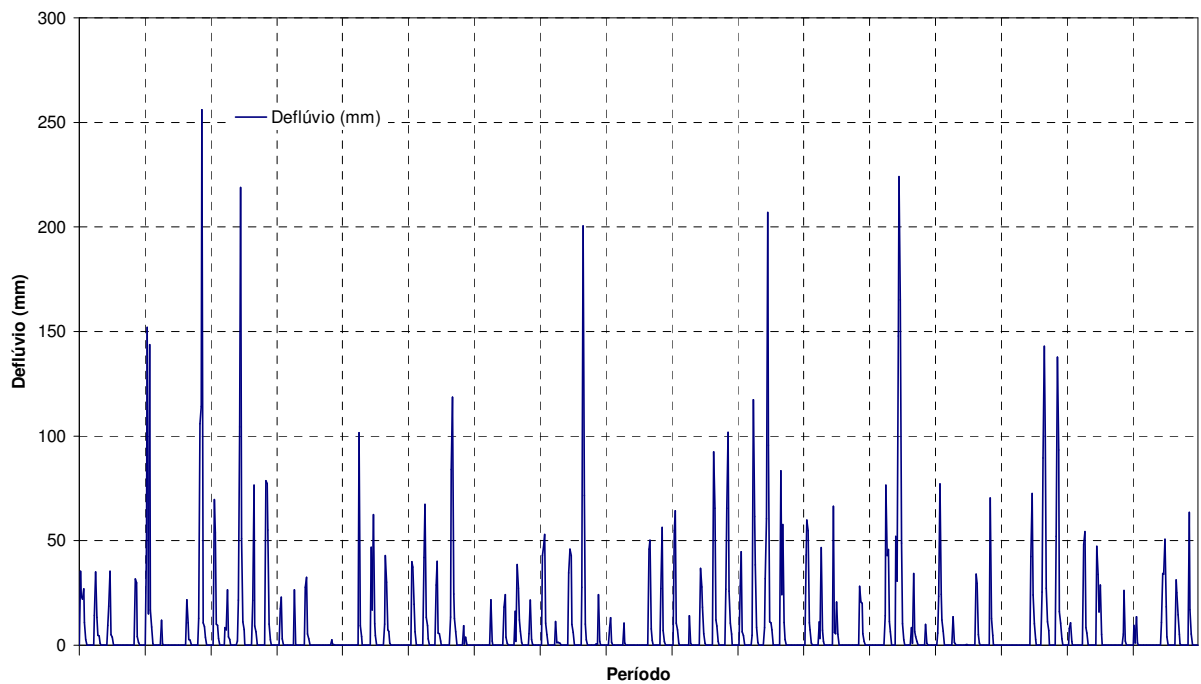


Figura 3.7 – Deflúvios Afluentes ao Reservatório Pacajus (1912 a 1996)




Figura 3.8 – Curva Cota x Área x Volume do Gavião

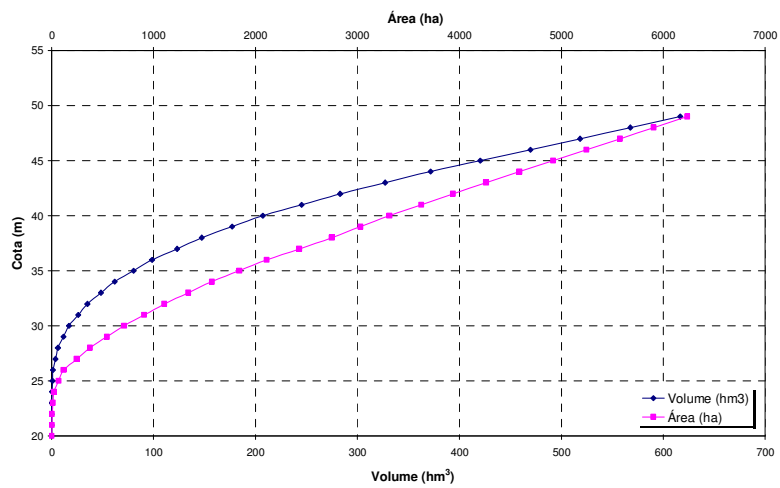


Figura 3.9 – Curva Cota x Área x Volume do Pacoti/Riachão




Figura 3.10 – Curva Cota x Área x Volume do Pacajus

3.3 – METODOLOGIAS

A **Figura 3.11** a seguir apresenta, de forma esquemática, as metodologias utilizadas nesta pesquisa e suas inter-relações. As descrições pormenorizadas das mesmas estão apresentadas na seqüência deste subitem. Destaque-se que, com exceção da geração da biblioteca de conhecimentos, na qual foi utilizado o pacote específico de programação dinâmica CSUDP (LABADIE, 1987), a implementação das demais metodologias foi realizada utilizando as ferramentas matemáticas presentes no pacote computacional Matlab®.

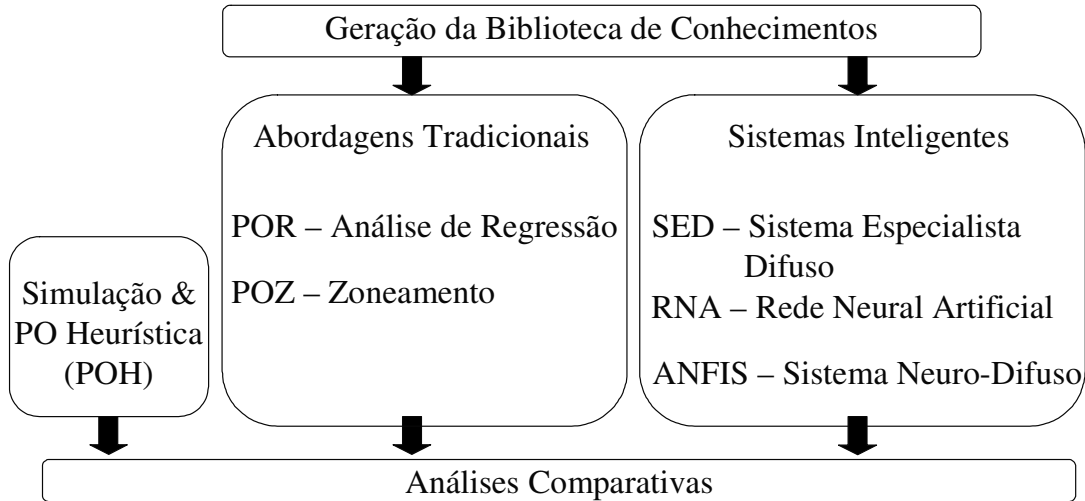


Figura 3.11 – Esquemas Metodológicos utilizados na Pesquisa

3.3.1 – TÉCNICA PARA GERAÇÃO DA BIBLIOTECA DE CONHECIMENTOS: PROGRAMAÇÃO DINÂMICA

3.3.1.1 – Programação Dinâmica Tradicional

O problema de operação de reservatórios é, em geral, um problema de controle ótimo discreto no tempo que pode ser representado matematicamente por:

$$\text{minimizar (maximizar)} J(\mathbf{U}) = \sum_{t=1}^N L(\mathbf{x}_t, \mathbf{u}_t, t) \quad (3.1)$$

sujeito a:

$$\mathbf{x}_{t+1} = T(\mathbf{x}_t, \mathbf{u}_t, t), \quad 1 \leq t \leq N \quad (3.2)$$

$$\mathbf{u}_t \in \{ \mathbf{u} : f(\mathbf{x}, \mathbf{u}, t) \leq 0 \} \quad (3.3)$$

onde $J(\mathbf{U})$ é a função-objetivo definida em função das políticas de operação \mathbf{u}_t (denominou-se \mathbf{U} a matriz formada pelos vetores \mathbf{u}_t , para $t = 1, \dots, N$); $L(\mathbf{x}, \mathbf{u}, t)$ é a função de retorno para cada estágio t ; $T(\mathbf{x}, \mathbf{u}, t)$ é a função que representa a dinâmica do sistema, ou seja, como

é seu comportamento entre dois estágios de tempo; e $f(\mathbf{x}, \mathbf{u}, t)$ são funções que determinam os valores possíveis de \mathbf{u}_t em cada estágio t .

Nesta pesquisa, considera-se que o problema apresenta as seguintes características:

- i) a variável de estado do sistema (\mathbf{x}) é um vetor real de dimensão n e a variável de controle (\mathbf{u}) é um vetor real de dimensão m ;
- ii) as funções de retorno $L(\mathbf{x}, \mathbf{u}, t)$ para cada estágio t e a função dinâmica de transição $T(\mathbf{x}, \mathbf{u}, t)$ são conhecidas;
- iii) o estágio inicial é dado e representado por \mathbf{x}_1 ; e
- iv) o horizonte final de decisão é escolhido e designado por N .

O objetivo principal da programação dinâmica, quando aplicada à operação de sistemas de reservatórios, é a determinação de uma política de operação para todo o processo que maximize ou minimize uma função-objetivo. O processo é dividido em uma série de estágios, divisão esta quase sempre feita em função de uma escala temporal. A computação é, então, feita em duas etapas: a primeira no sentido inverso à escala temporal (*backward run*) e a segunda no mesmo sentido da escala de tempo (*forward run*). Baseando-se no problema definido pelas equações (3.1) a (3.3), as etapas de computação do processo tradicional de programação dinâmica podem ser descritas como segue.

Seja uma função $V(\mathbf{x}, t)$, denominada função de retorno, definida para o estado-tempo (\mathbf{x}, j) de acordo com a regra:

$$V(\mathbf{x}, j) = \sum_{t=j}^N L(\mathbf{x}_t, \mathbf{u}_t, t) \quad (3.4)$$

A primeira etapa tem início com a definição de $V(\mathbf{x}, t)$ para o estágio $N+1$ de forma que:

$$V^*(\mathbf{x}; N+1)=0; \text{ para todo estado } \mathbf{x} \quad (3.5)$$

onde o $*$ indica o valor ótimo da função de retorno. Para os demais estágios de tempo, $t = N, N-1, \dots, 1$, definem-se, então, para todo estado \mathbf{x} do sistema, as seguintes relações:

$$V^*(\mathbf{x}; t) = \min_{\mathbf{u}} [L(\mathbf{x}, \mathbf{u}, t) + V^*(T(\mathbf{x}, \mathbf{u}, t), t+1)] \quad (3.6)$$

e

$$S(\mathbf{x}; t) = \mathbf{u}^* \quad (3.7)$$

onde \mathbf{u}^* é um valor que minimiza o lado direito da equação (3.6). Quando $S(\mathbf{x}; t)$ tiver sido definido para $t = N-1, N-2, \dots, 1$, a primeira etapa da computação (*backward run*) estará completa. Prossegue-se, então, com a segunda etapa do processo de programação dinâmica.

Esta etapa (*forward run*) tem início fazendo-se $\mathbf{x}_1^* = \mathbf{x}_1$, valor preestabelecido para o estado inicial do sistema. Para os estágios $t = 1, 2, \dots, N$ calcula-se, então, $\mathbf{u}^*(t)$ por meio do seguinte esquema:

$$\mathbf{u}^*(t) = S(\mathbf{x}^*(t), t) \quad (3.8)$$

e

$$\mathbf{x}^*(t+1) = T(\mathbf{x}^*(t), \mathbf{u}^*(t), t) \quad (3.9)$$

Isto conclui o procedimento de programação dinâmica e é fácil demonstrar que, se este esquema puder ser implementado, $\mathbf{U}^* = (\mathbf{u}_1^*, \dots, \mathbf{u}_N^*)$ é um controle ótimo.

A grande desvantagem desse esquema é que, para a maioria das funções $L(\cdot)$ e $T(\cdot)$ utilizadas em problemas de controle ótimo, ele não poderá ser implementado computacionalmente. Mesmo que isso seja possível, utilizando-se algumas técnicas auxiliares como a discretização das variáveis do problema (programação dinâmica discreta), o volume de armazenamento de dados (memória computacional) que é exigido tornaria proibitiva sua aplicação em sistemas complexos.

Para superar essas dificuldades, tornando possível o aproveitamento das vantagens da programação dinâmica, é que LABADIE (1987) elaborou um pacote computacional (*CSUDP – Multidimensional Dynamic Programming*) que faz uso de duas técnicas de PD: a Programação Dinâmica Incremental (PDI), utilizada nesta pesquisa e descrita no item seguinte, e a Programação Dinâmica por Aproximações Sucessivas (PDAS), que, apesar de mais rápida que a anterior, pode levar a ótimos locais distantes do ótimo global.

3.3.1.2 – Programação Dinâmica Incremental

A técnica de Programação Dinâmica Incremental (PDI) se baseia na intuição de como será a solução ótima. Cria-se, inicialmente, um grupo de *trajetórias tentativas*. Pode-se definir *trajetória* como a linha formada pelos valores médios das variáveis de estado, plotadas para cada estágio.

Na **Figura 3.12** a seguir, a trajetória inicial está representada por uma linha contínua. Entretanto, está é na verdade composta por um número infinito de pontos discretos.

Após a definição da trajetória inicial, é estabelecido, em torno da mesma, um *corredor*, considerando-se uma faixa Δx (sendo x o vetor-variável de estado do problema em estudo) tanto para cima como para baixo da trajetória. O Δx a ser adotado dependerá da precisão desejada para a solução do problema, sendo aconselhável usar-se um corredor com uma largura inicial, caso esta seja variável, um pouco maior.

Para cada estágio, tem-se agora três valores discretos para cada componente do vetor de variáveis de estado x , de modo que o número de combinações de soluções será 3^m , sendo m o número de componentes (e.g., reservatórios) do sistema em estudo. O problema é resolvido apenas para as variáveis dentro do *corredor*, obtendo-se uma nova trajetória de valores ótimos (**Figura 3.13a**). Utilizando o Δx adotado anteriormente, ou um valor menor (dependendo da precisão desejada), define-se um novo corredor (**Figura 3.13b**). Esse procedimento é repetido até que as trajetórias finais coincidam.

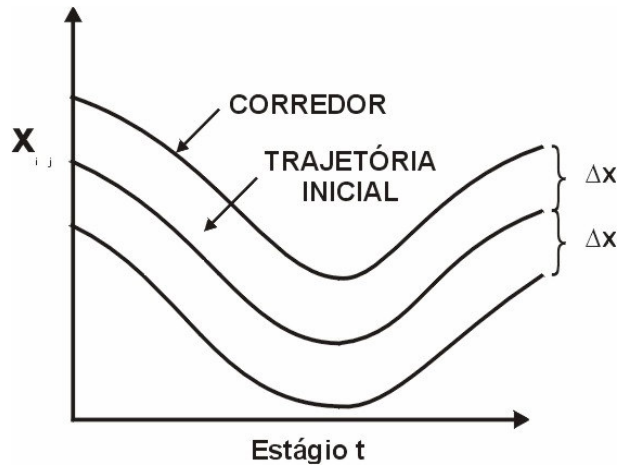


Figura 3.12 – Trajetória Tentativa e seu Corredor para a Variável de Estado na PDI




Figura 3.13 (a) – Solução para as variáveis dentro do corredor

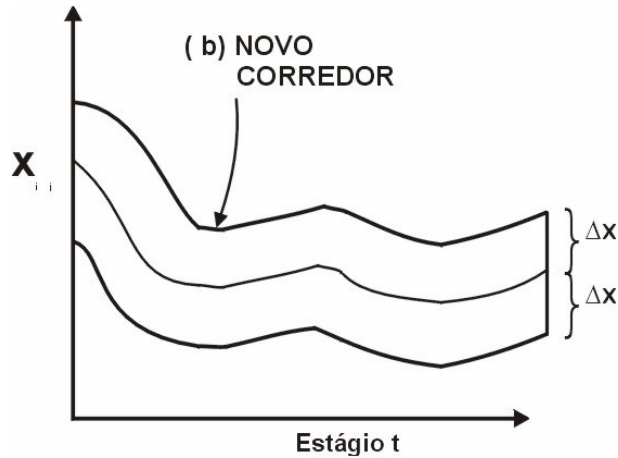


Figura 3.13 (b) – Definição de um novo corredor.

É importante ressaltar que por esse procedimento pode-se garantir apenas uma solução ótima local. Deve-se, portanto, resolver o problema adotando-se várias trajetórias iniciais diferentes, sendo a solução a melhor trajetória final obtida.

3.3.2 – TÉCNICA (MODELO) DE SIMULAÇÃO E A POLÍTICA OPERACIONAL HEURÍSTICA

A oferta hídrica de um reservatório ou de um sistema de reservatórios corresponde à vazão por ele(s) regularizada, sempre associada a uma determinada garantia. Para obtenção da oferta hídrica, pode-se utilizar um processo (modelo) de simulação.

A simulação baseia-se na equação de balanço de massa do sistema em análise, equação essa que pode ser expressa matematicamente por:

$$X_{t+1} = X_t - (E_t - P_t) \frac{(A_t + A_{t+1})}{2} + Q_t^{Bac.Incr.} + u_t^e - u_t^s - V_t \quad (3.10)$$

onde: X_{t+1} e X_t são vetores cujos componentes são as variáveis de estado do sistema nos intervalos de tempo $t+1$ e t , respectivamente; E_t e P_t são vetores com as evaporações e as precipitações, respectivamente, para cada reservatório do sistema no intervalo de tempo t ; A_t e A_{t+1} são vetores com as áreas dos espelhos líquidos dos reservatórios (áreas das bacias hidráulicas) nos intervalos de tempo t e $t+1$; $Q_t^{Bac.Incr.}$ é o vetor de vazões não-controladas afluentes aos reservatórios no intervalo de tempo t ; u_t^e é o vetor de vazões controladas afluentes aos reservatórios no intervalo de tempo t ; u_t^s é o vetor de vazões controladas efluentes dos reservatórios no intervalo de tempo t ; e V_t é o vetor de vazões não-controladas efluentes dos reservatórios (vertimentos) no intervalo de tempo t .

Sempre que o sistema apresentar um volume inferior à retirada desejada (demanda), apenas uma parte desta é satisfeita, denominando-se esse evento como uma *falha*. Para um

determinado período de análise com n intervalos de tempo simulados, se em f deles a demanda não foi totalmente satisfeita, pode-se determinar a garantia de abastecimento por:

$$g = \left(1 - \frac{f}{n}\right) \cdot 100 \quad (3.11)$$

A vazão regularizada está, portanto, sempre associada a um nível de garantia $g\%$.

A política operacional mais comumente utilizada, denominada neste texto *Política Operacional Heurística* (POH), por ser obtida a partir da experiência dos técnicos da região, pode ser expressa matematicamente por:

$$X_{t+1} = X_t - (E_t - P_t) \frac{(A_t + A_{t+1})}{2} + Q_t^{Bac.Incr.} + u_t^e - u_t^s - V_t \quad (3.12a)$$

$$u_t^s = \begin{cases} Q_{reg} & \text{se } X_{t+1} \geq X_{min} \\ Q_{falha} = X_t - (E_t - P_t) \frac{(A_t + A_{t+1})}{2} + Q_t^{Bac.Incr.} + u_t^e - X_{min} & \text{se } X_{t+1} < X_{min} \\ 0 & \text{se } [X_t - (E_t - P_t) \frac{(A_t + A_{t+1})}{2} + Q_t^{Bac.Incr.} + u_t^e] < X_{min} \end{cases} \quad (3.12b)$$

$$X_{t+1} \leq X_{max}, t = 1, 2, \dots, n \quad (3.12c)$$

onde X_{min} e X_{max} são, respectivamente, os volumes operacionais mínimo e máximo do reservatório; Q_{reg} é a vazão regularizada que está sendo testada; sendo as demais variáveis as mesmas da equação 3.10.

Os estudos sobre operação de reservatórios têm demonstrado que, no Nordeste brasileiro (NEB), a estrutura temporal das falhas apresenta concentrações interanuais, com períodos de falhas superiores a dois anos. Este fato torna o conceito de vazão garantida em 90% do tempo muito arriscado para o desenvolvimento de atividades econômicas na região, pois claro está ser inviável, seja para abastecimentos humano e industrial, seja para agricultura irrigada, aceitar-se um déficit hídrico tão prolongado. Uma alternativa encontrada foi modificar o conceito de *vazão garantida*, associando à mesma a obrigação de suprir durante os períodos de falha uma vazão menor: habitualmente entre 30% e 75% da vazão garantida em 90% do tempo, sendo esta a vazão a ser suprida entre 80% a 100% do tempo restante. A política operacional heurística (POH) apresentada na equação 3.12 é modificada, incorporando-se na mesma o conceito de *volume de alerta*, volume a partir do qual a liberação de vazão é restringida à citada fração da vazão regularizada. Por conseguinte, pode-se representar a POH de simulação por:

$$X_{t+1} = X_t - (E_t - P_t) \frac{(A_t + A_{t+1})}{2} + Q_t^{Bac.Incr.} + u_t^e - u_t^s - V_t \quad (3.13a)$$

$$u_t^s = \begin{cases} Q_{reg} & \text{se } X_t \geq X_{alerta} \\ \%Q_{reg} & \text{se } X_{\min} \leq X_t < X_{alerta} \\ Q_{falha} < \%Q_{reg} & \text{se } X_{t+1} \geq X_{\min} \\ 0 & \text{se } [X_t - (E_t - P_t) \frac{(A_t + A_{t+1})}{2} + Q_t^{Bac.Incr.} + u_t^e] < X_{\min} \end{cases} \quad (3.13b)$$

$$X_{t+1} \leq X_{\max}, t = 1, 2, \dots, n \quad (3.13c)$$

onde $\%Q_{reg}$ representa uma fração da vazão regularizada e X_{alerta} é um volume de alerta predeterminado, maior do que o volume mínimo operacional do reservatório.

3.3.3 – ABORDAGENS (METODOLOGIAS) TRADICIONAIS

Tradicionalmente na operação de reservatórios, as políticas operacionais adotadas ou são heurísticas, como a mostrada no **item 3.2** anterior, ou são obtidas por uma das seguintes maneiras:

- ✓ **Análise de Regressão:** a partir de uma base de conhecimentos, obtida geralmente por técnicas de otimização, como as mostradas no capítulo 2 desta tese, e utilizando técnicas de regressão, expressam-se as políticas operacionais matematicamente a partir de funções que relacionam as retiradas de cada componente do sistema com o(s) estado(s) do(s) reservatório(s) e/ou com as variáveis hidrológicas de entrada, particularmente as vazões afluentes. Essas relações permitem ao operador do sistema determinar qual a retirada com base na informação disponível;
- ✓ **Zoneamento do(s) Reservatório(s):** a partir da experiência dos operadores ou de uma base de conhecimentos, faz-se o zoneamento dos reservatórios, sendo a decisão do operador do sistema retirar um valor fixo arbitrado de vazão para cada uma das faixas do(s) reservatório(s).

Na análise de regressão utilizada nesta pesquisa, foram consideradas as seguintes equações gerais:

$$u_t^{Pcr} = a_0 + a_1X_1 + a_2X_2 + \dots + a_pX_p \quad (3.14a)$$

$$u_t^{Pac} = b_0 + b_1X_1 + b_2X_2 + \dots + b_pX_p \quad (3.14b)$$

$$u_t^{Cnl} = c_0 + c_1X_1 + c_2X_2 + \dots + c_pX_p \quad (3.14c)$$

onde u^{Pcr}_t , u^{Pac}_t e u^{Cnl}_t representam, respectivamente, as retiradas dos açudes Pacoti/Riachão, do açude Pacajus e do Canal do Trabalhador (variáveis dependentes), x_i são as variáveis independentes, com $i = 1, 2, \dots, p$, sendo p o número de variáveis independentes, e a , b e c são os parâmetros de ajuste (coeficientes de regressão) dos modelos.

O Volume Total do Sistema no intervalo de tempo t (VTS_t), os volumes individuais de cada um dos reservatórios no intervalo de tempo t ($V^{Pac}_t =$ volume do açude Pacajus no tempo t ; $V^{Pcr}_t =$ volume dos açudes Pacoti/Riachão no tempo t ; $V^{Gav}_t =$ volume do açude Gavião no tempo t) e as vazões afluentes a cada um dos reservatórios no intervalo de tempo $t-1$ ($Q^{Pac}_{t-1} =$ vazão afluente ao açude Pacajus no tempo $t-1$; $Q^{Pcr}_t =$ vazão afluente aos açudes Pacoti/Riachão no tempo $t-1$; $Q^{Gav}_t =$ vazão afluente ao açude Gavião no tempo $t-1$) foram utilizados, individualmente e em conjunto, como variáveis independentes (x_i 's) na composição de diferentes modelos matemáticos representativos, adotando-se, para comparação com as demais metodologias, o de melhor ajuste segundo os indicadores de desempenho apresentados no **item 3.4** desta tese. Os parâmetros dos modelos foram ajustados pelo método dos mínimos quadrados, considerando um conjunto de dados para ajuste e outro para validação dos modelos.

O zoneamento dos reservatórios considerou a seguinte regra geral: a obtenção das retiradas foi realizada por meio da equivalência entre o volume do reservatório de jusante e o tempo de bombeamento com base nos histogramas de frequência para as retiradas mensais ótimas obtidas, conforme metodologia apresentada no **item 3.3.1**. A **Figura 3.14** ilustra esse procedimento.




Figura 3.14 – Esquema de Zoneamento dos Reservatórios do Sistema

3.3.4 – METODOLOGIAS BASEADAS EM INTELIGÊNCIA ARTIFICIAL (IA)

3.3.4.1 – Modelo baseado em Lógica Difusa

A implementação dos modelos baseados em lógica difusa foi realizada considerando três etapas: identificação dos modelos, treinamento ou ajuste das regras e validação do modelo, conforme se descreve em detalhe a seguir.

3.3.4.1.1 – Identificação dos Modelos

Na presente pesquisa, a identificação dos modelos consiste na investigação do grupo de variáveis, bem como do número de conjuntos difusos adotados para estas, que proporcionam melhores políticas operacionais para o sistema de reservatórios. O processo de seleção das variáveis envolve a identificação das variáveis independentes (entradas) e dependentes (saídas) que descrevam o comportamento do sistema. Não existe um método para identificação das variáveis relevantes, sendo geralmente baseado no conhecimento do especialista e na análise prévia dos dados por meio de visualizações gráficas ou análises estatísticas.

No caso desta pesquisa, as principais variáveis que podem ser utilizadas no modelo são os volumes armazenados nos reservatórios individualmente e no sistema como um todo, as precipitações, as vazões afluentes e retiradas (vazões efluentes) dos reservatórios, além de variáveis semânticas (qualitativas) que caracterizam a estação do ano ou indicam a qualidade da estação chuvosa do ano seguinte. Inicia-se o processo de identificação com testes de estruturas mais simples, incrementando progressivamente. É testada em primeiro lugar a qualidade das políticas operacionais obtidas considerando-se como antecedentes apenas os volumes passados dos reservatórios para a previsão das retiradas futuras. São realizadas, então, investigações sucessivas, acrescentando-se como antecedentes o volume passado total do sistema, as precipitações, as vazões afluentes e as variáveis semânticas. Essas variáveis foram acrescentadas isoladamente e em conjunto na busca dos melhores resultados.

A partição dos domínios das variáveis selecionadas visa à representação das variáveis numéricas como variáveis lingüísticas. Um aspecto importante nesse processo é a escolha do número de partições de cada variável. Muitas partições resultam em grande quantidade de parâmetros a serem ajustados, enquanto um número pequeno de partições pode resultar em modelos que não conseguem representar a relação presente no conjunto de dados. Tão importante quanto o número de partições é o modo de partição. A maneira mais simples é a

divisão do domínio em intervalos de tamanhos iguais, mas métodos de reconhecimento de padrões podem ser utilizados para identificação automática das partições.

A definição das variáveis lingüísticas se completa com a atribuição de uma função de pertinência e um termo lingüístico para cada partição de domínio. A atribuição de funções de pertinência para cada partição de domínio das variáveis é ainda uma questão em aberto na modelagem de sistemas difusos. Não há consenso sobre qual forma de função de pertinência é mais adequada para cada tipo de problema, já que até o momento as pesquisas não comprovaram maior eficácia de uma forma em relação às demais. Por esse motivo, as formas mais simples (triangulares e trapezoidais) são as mais utilizadas. Definida a forma, inicia-se a escolha dos parâmetros de cada função. Quando a forma triangular é utilizada, esses parâmetros correspondem aos valores extremos (mínimo e máximo da partição), aos quais são atribuídos graus zero de pertinência, e à média dos valores encontrados na partição, à qual é atribuído grau de pertinência 1 (um). No caso das funções trapezoidais, são atribuídos graus zero de pertinência aos valores mínimo e máximo da partição, mas os outros dois parâmetros são definidos, em geral, subjetivamente. Em todos os casos, os parâmetros das funções de pertinência constituem o conjunto de parâmetros a ser ajustado no processo de treinamento do sistema de regras. Por fim, para distinguir as diversas partições, atribui-se um termo lingüístico adequado para cada uma.

Nesta pesquisa, as variáveis foram particionadas utilizando um método de agrupamento para reconhecimento de padrões. O algoritmo de agrupamento utilizado foi o *fuzzy c-means* (FCM) proposto por Bezdek (1981) citado por AMIRI (2003). Esse provê um método que mostra como se agrupar dados que povoam algum espaço multidimensional em um número específico de agrupamentos diferentes. Utilizando a distância de um ponto ao centro do agrupamento, o algoritmo estabelece uma relação de pertinência μ_{ik} ao conjunto dos dados analisados. Um agrupamento tem o seu centro definido por:

$$v_i = \frac{\sum_{k=1}^N \mu_{ik}^m x_k}{\sum_{k=1}^N \mu_{ik}^m}, \quad i = 1, \dots, C \quad \text{com } x_k = (x_{k1}, x_{k2}, \dots, x_{kj}) \quad (3.15)$$

onde i é o número de classes, j é o número de variáveis e m é o índice de fuzificação (expoente difuso), que varia de 1 a ∞ . O erro das amostras é:

$$J(U, V) = \sum_{k=1}^N \sum_{i=1}^c \mu_{ik}^m (d_{ik})^2 \quad (3.16)$$

onde V é uma matriz que contém os centros de cada agrupamento, U é a matriz de dimensão $C \times N$ que contém todas as pertinências μ_{ik} dos pontos do agrupamento, C é o número de agrupamentos, N a sua quantidade de pontos e d_{ik} é a distância Euclidiana entre x_k e o centro do agrupamento v_i . Por ser um algoritmo fuzzy, um ponto pode ter pertinência a mais de um agrupamento. A matriz de partição U tem as seguintes propriedades:

- ✓ a soma dos valores de pertinência de um registro à todas as classe é igual a 1 (um), ou seja, a soma de todas as linhas da matriz U é igual a 1;
- ✓ todo registro deve pertencer ao menos a um agrupamento e nenhum agrupamento pode conter todos os registros, ou seja, a soma de todas as colunas da matriz U deve ser maior que 0 e menor que C .

O algoritmo *FCM* realiza uma otimização iterativa do critério de erro (equação 3.16), utilizando os valores de centros dos agrupamentos para o cálculo da matriz U e a nova matriz U para o cálculo de novos valores para os centros dos agrupamentos.

Em geral, mais de uma alternativa de agrupamento pode ser considerada satisfatória para a configuração dos agrupamentos. É importante, portanto, que seja evitada a escolha de um número de classes intermediário entre duas boas alternativas. Para auxiliar nesse processo, utilizou-se o cálculo de indicadores (coeficientes de eficiência) para determinar o número mais adequado de classes (c). A seguir, são apresentados comentários sobre os indicadores utilizados nesta pesquisa, quais sejam: o Índice de Validade (V_d) e o Coeficiente de Partição Difusa (F_c ou P_d).

O *Índice de Validade do agrupamento* (V_d) foi proposto por FUKUYAMA e SUGENO (1989). É um índice que explora a compacidade e a separação entre grupos. Matematicamente, este é expresso por:

$$Vd = \sum_{k=1}^N \sum_{j=1}^C \mu_{jk}^m \|V_j - x_k\|^2 - \sum_{k=1}^N \sum_{j=1}^C \mu_{jk}^m \|V_j - \bar{V}\|^2 \quad (3.17)$$

Segundo os autores, um valor mínimo para esse indicador corresponde a agrupamentos compactos e bem separados. Observa-se, entretanto, a ocorrência de sucessivos mínimos, devendo-se considerar apenas o primeiro como confiável.

O *Coeficiente de Partição Difusa* (F_c ou P_d) é uma medida do sucesso da decomposição do conjunto de dados em classes (Bezdek, 1974 apud **Ross, 2004**). Matematicamente pode ser expresso por:

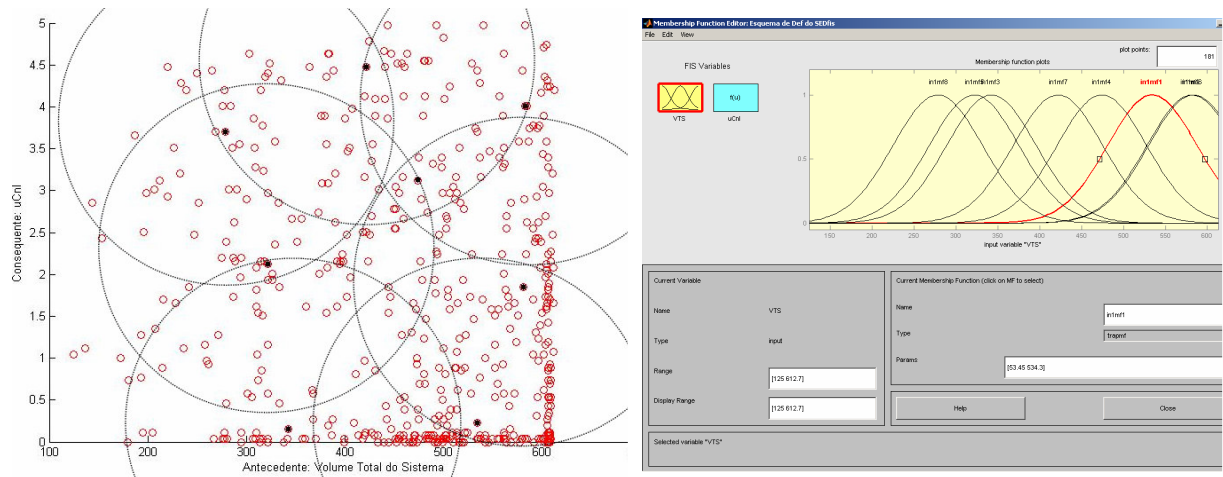
$$Pd = \frac{tr(U * U^T)}{K} \quad (3.18)$$

onde U é a matriz de partição difusa que está sendo segregada em c classes (partições), K é o número de registro de dados, tr indica a soma dos elementos da diagonal da matriz produto $U * U^T$ e a operação $*$ é a multiplicação padrão de matrizes. O produto $U * U^T$ é uma matriz $c \times c$. Os elementos da diagonal desta matriz são proporcionais às pertinências não compartilhadas dos conjuntos de dados às classes difusas. Se o coeficiente resulta 1 (um), o método difuso é, portanto, desnecessário. Por outro lado, se resulta $1/c$, a classificação é irrelevante, pois os dados pertencem a todas as classes (partição totalmente ambígua/ difusa), com graus iguais e muito pequenos. O número máximo para o coeficiente corresponde à melhor partição (melhor c).

A principal dificuldade na utilização desse coeficiente é a tendência de diminuição do valor com o aumento do número de classes. Essa diminuição, no entanto, não é monotônica, havendo perturbações à medida que aumenta o número de classes. Estas perturbações correspondem às situações em que ocorrem melhoras no desempenho com o acréscimo de um novo agrupamento. Com o objetivo de eliminar os efeitos do compartilhamento mínimo, pode-se subtrair deste coeficiente o valor $1/c$, obtendo-se o *Coefficiente de Partição Difusa Significativa* (Pd_{sig}). Os valores máximos de Pd_{sig} representam as configurações mais favoráveis de agrupamento.

Definidos o número de agrupamentos e os protótipos (centros dos agrupamentos), o processo de identificação dos modelos prossegue com a definição da configuração inicial do sistema especialista difuso (SED). Cada antecedente e cada conseqüente terá tantas funções de pertinência quantos forem os números de agrupamentos que melhor representam o conjunto de dados em análise. Para uma determinada variável, cada função de pertinência representará as características de um dos agrupamentos (protótipos) identificados, tanto em posição (centro), como em influência. A **Figura 3.15** ilustra esse processo para o caso particular de um SED com um antecedente e um conseqüente.


As funções de pertinência testadas nesta pesquisa foram as dos seguintes tipos, ilustrados na **Figura 3.16**: triangular, trapezoidal, forma de sino e curva de Gauss.




(a) Representação dos Dados e dos Centros dos Agrupamentos

(b) Definição das Funções de Pertinência


Figura 3.15 – Esquema geral de definição da configuração inicial dos Sistemas Especialistas Difusos a partir da análise de agrupamento




(a) Tipo Triangular



(b) Tipo Trapezooidal



(c) Forma de Sino



(d) Curva de Gauss

Fonte: Manual do Usuário – Toolbox de Lógica Difusa do Matlab

Figura 3.16 – Tipos de Função de Pertinência testados na pesquisa

Na fase de descrição das regras, uma base inicial foi descrita e posteriormente ajustada para representar, da melhor forma possível, o conhecimento especialista e/ou o conhecimento implícito nos dados disponíveis. Nesse processo, as proposições *antecedentes* e *conseqüentes* de cada regra são descritas considerando as possíveis interações entre as variáveis selecionadas. Quanto menos interações são consideradas, menos regras são necessárias. Um sistema que não considera nenhuma interação entre as variáveis terá a seguinte forma:

$$\begin{aligned}
R_1: & \quad \mathbf{Se} (x_1 \text{ é } A_{i,1}) \mathbf{Então} (y \text{ é } B_i) \\
R_2: & \quad \mathbf{Se} (x_2 \text{ é } A_{j,2}) \mathbf{Então} (y \text{ é } B_j) \\
& \dots \qquad \dots
\end{aligned} \tag{3.19}$$

onde x_1, x_2, \dots, x_k, y são variáveis difusas sobre diferentes universos de domínio $U_{x_1}, U_{x_2}, \dots, U_{x_k}, U_y$, e $A_{k,n}$ e B_n são seus possíveis valores difusos sobre os mesmos universos de domínio, sendo k o número de variáveis de entrada. Se p é o número de termos lingüísticos associados a cada variável, o número máximo de regras nesse sistema será kp .

No caso em que interações entre as variáveis são consideradas, as regras do sistema terão a seguinte forma:

$$\begin{aligned}
R_1: & \quad \mathbf{Se} (x_1 \text{ é } A_{1,1}) \mathbf{E} (x_2 \text{ é } A_{2,1}) \dots \mathbf{E} (x_k \text{ é } A_{k,1}) \mathbf{Então} (y \text{ é } B_1) \\
R_2: & \quad \mathbf{Se} (x_1 \text{ é } A_{1,2}) \mathbf{E} (x_2 \text{ é } A_{2,2}) \dots \mathbf{E} (x_k \text{ é } A_{k,2}) \mathbf{Então} (y \text{ é } B_2) \\
& \dots \qquad \dots
\end{aligned} \tag{3.20}$$

e o número máximo de regras será de p^k , crescendo, portanto, exponencialmente com o número de variáveis de entrada e de termos lingüísticos definidos para estas variáveis.

No processo de descrição das regras, deve-se ter em mente, portanto, que o número destas deve ser determinado cuidadosamente, a fim de evitar uma quantidade excessiva de parâmetros no modelo. O excesso de parâmetros poderá ocasionar um superajuste (*overfitting*), fazendo com que o modelo perca a capacidade de generalização. Para saber se uma determinada regra pode ser removida do sistema, deve-se avaliar o sistema *com* e *sem* a regra. Se as respostas forem parecidas, a regra pode ser removida.

3.3.4.1.2 – Treinamento ou Ajuste das Regras

Como já definido anteriormente, o treinamento, ou ajuste, das regras é a etapa em que os parâmetros das funções de pertinência associadas aos termos lingüísticos são ajustados com base em um conjunto de dados. Esse processo é também denominado *Aprendizado Difuso*. Por mais criteriosas que tenham sido a seleção das variáveis e a escolha das funções de pertinência, raramente o sistema de regras inicialmente definido representará bem a relação entre as variáveis de entrada e de saída do sistema.

A maior dificuldade do processo de treinamento se deve à inexistência de um método bem definido. Em geral há muitos graus de liberdade, pois uma mesma alteração na resposta do sistema pode ser obtida com a alteração dos parâmetros das funções de pertinência do antecedente ou do conseqüente, ou ainda com a simples alteração da forma dessas funções.

O processo de aprendizado organizativo definido por PEDROLLO e LANNA (2000) foi utilizado na presente pesquisa. O procedimento estabelecido pelo autor para a pesquisa de regras associativas na Matriz Cognitiva está ilustrado na **Figura 3.17** e possui três objetivos:

- ✓ determinar qual é o conjunto difuso da variável explicada com maior somatório ponderado de ocorrências (Z_M), para cada combinação possível dos antecedentes;
- ✓ transformar o valor deste elemento da matriz em uma frequência (Fr), em relação ao total de ocorrências ponderadas, para a combinação analisada;
- ✓ decidir se a frequência observada é suficientemente significativa, tendo em conta o número de conjuntos do conseqüente e um valor mínimo estabelecido; se a decisão for favorável, forma-se a regra associativa.

Para cada combinação de antecedentes, faz:

$$S_z = \sum_{z_j=1}^{n_{z_j}} M(\text{antecedentes}, z_j)$$

$$M_z = \max_{z_j=1, \dots, n_{z_j}} [M(\text{antecedentes}, z_j)]$$

{ z_j = conjunto difuso conseqüente }

Z_M = z_j correspondente a M_z

$$Fr = 100M_z/S_z$$

{ Fr = frequência calculada para Z_M }

Se $Fr \geq$ limite de significância, resulta,

Regra: (antecedentes; $z_j=Z_M$) : $w_r = Fr$

Fim se;

Fim para;

Fonte: Pedrollo (2000)

Figura 3.17 – Algoritmo de Pesquisa das regras na Matriz Cognitiva

A avaliação de quão bem o sistema de regras treinado representou a relação de entrada/saída contida nos dados foi feita por intermédio de um indicador de desempenho apresentado posteriormente neste texto.

3.3.4.1.3 – Validação do Modelo

Conforme definido anteriormente, a validação é o processo em que o modelo é avaliado quanto ao seu desempenho. Uma questão importante e que merece destaque,

relacionada com a avaliação da capacidade de generalização de um modelo, é a seleção adequada do conjunto de validação. Esse deve ser, ao mesmo tempo, representativo do domínio de valores que o modelo busca representar e suficientemente distinto do conjunto de treinamento para que o processo de validação não se torne trivial. Quando o desempenho de um conjunto de regras difusas é considerado insatisfatório, um novo conjunto de variáveis e/ou regras é selecionado e o modelo é novamente ajustado e validado.

3.3.4.2 – Modelo baseado em Redes Neurais Artificiais

Assim como os sistemas de regras difusas, as redes neurais artificiais (RNA) são instrumentos para expressar o conhecimento empírico adquirido da relação entre variáveis dependentes e independentes de um sistema. Em vez de regras, o conhecimento é representado por um conjunto de parâmetros associados a unidades de processamento interconectadas em uma estrutura de rede. A forma como as unidades de processamento e suas interconexões estão estruturadas determina o tipo de RNA. O grafo arquitetural típico de uma rede neural já foi mostrado na **Figura 2.2**.

A qualidade do modelo de redes neurais dependerá da escolha de um tipo de rede neural adequado ao problema que se está modelando. A princípio, nenhum tipo de rede pode garantir respostas sempre corretas para o modelo. Assim como no desenvolvimento de modelos baseados em lógica difusa, o desenvolvimento de um modelo baseado em redes neurais se dá em três etapas: identificação do modelo, treinamento da rede e validação do modelo.

3.3.4.2.1 – Identificação dos Modelos

A identificação do modelo começa, como em quase todos os processos de modelagem, com a seleção das variáveis que explicam a relação que se deseja modelar. Como nem todas as variáveis estão explicitamente apresentadas, elas podem ser identificadas em um processo de tentativa e erro, em que modelos construídos com diferentes conjuntos de variáveis são avaliados comparativamente em termos da capacidade de produzir soluções satisfatórias para o problema.

No caso desta pesquisa, as seguintes variáveis foram utilizadas na montagem dos modelos: volumes armazenados nos reservatórios e no sistema como um todo, precipitações, vazões afluentes, retiradas (vazões efluentes) dos reservatórios, variáveis que caracterizam a estação chuvosa (seca, intermediária ou chuvosa), e variáveis de previsão da estação chuvosa do ano seguinte ou do mês seguinte.


Tão difícil quanto a seleção das variáveis é a tarefa de definição de uma topologia para a rede, fundamental para um bom desempenho do modelo. A arquitetura básica de rede utilizada nesta pesquisa é a denominada *Perceptrons de Múltiplas Camadas (MLP, multilayer perceptron)*.

Os números de unidades de entrada e saída são determinados com base no número de variáveis de entrada e saída. Para a determinação do número de camadas e unidades de processamento ocultas, no entanto, não existe uma regra estabelecida. O processo normalmente ocorre de forma empírica. Deve-se considerar, nesse processo, que um número muito alto de unidades ocultas relativamente ao número de exemplos disponíveis pode levar ao fenômeno conhecido como “memorização”, perdendo a rede a sua capacidade de generalização. Por outro lado, um número reduzido de unidades ocultas pode ter como consequência a dificuldade de aprendizado pela rede.


É recomendável que se inicie a busca da arquitetura da rede a partir de estruturas mais simples, com poucas unidades ocultas, aumentando o número dessas, gradualmente, à medida que melhores resultados sejam obtidos. Nesta pesquisa, os testes das topologias foram iniciados com apenas uma camada oculta com um número reduzido de unidades de processamento. Um número maior de camadas e um número crescente de unidades de processamento em cada camada foram, então, testados e os resultados comparados por meio de medidas de erro.

A função atribuída a cada unidade de processamento pode variar conforme a camada em que a unidade se encontra. As unidades de processamento da camada de entrada têm normalmente associadas funções denominadas *funções de escala*, que servem para transformar o domínio de valores dos sinais de entrada para o domínio no qual o processamento é mais eficiente, geralmente o intervalo $[0,1]$ ou $[-1,1]$. As funções atribuídas às unidades de processamento das camadas ocultas e de saída são denominadas *funções de transferência* ou *funções de ativação*.

A escolha dessas funções depende da relação entrada-saída para a qual se quer treinar a rede, requerendo sempre, no entanto, a avaliação de diferentes alternativas. Nesta pesquisa, foram testadas como funções de transferências a linear por partes (rampa) e a sigmóide, representadas esquematicamente na **Figura 3.18**.



(a) Função Linear por Partes (Rampa)



(b) Função Sigmóide

Figura 3.18 – Tipos de Funções de Transferência testados na pesquisa

Matematicamente, estas funções podem ser expressas pelas seguintes equações:

Função Linear por Partes (Rampa):

$$\varphi(v) = \begin{cases} 1, \forall v \geq 1 \\ v, \forall |v| < 1 \\ -1, \forall v \leq -1 \end{cases} \quad (3.21)$$

Função Sigmóide

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (3.22)$$

onde v é a entrada líquida obtida a partir das entradas no neurônio e dos pesos sinápticos com o uso de uma regra de propagação. O parâmetro a na função sigmóide é um parâmetro de inclinação da curva. A regra de propagação utilizada nesta pesquisa pode ser expressa matematicamente por:

$$v_k = \sum_{j=0}^n w_{kj} \cdot x_j \quad (3.23)$$

onde v_k é a entrada líquida no neurônio de ordem k ; x_j são as entradas no neurônio de ordem k ; e w_{kj} são os pesos sinápticos referentes às conexões com o neurônio de ordem k .

3.3.4.2.2 – Treinamento da Rede

Treinamento é o processo no qual a rede “aprende” a relação contida num conjunto de dados, referido geralmente como *conjunto de treinamento*. Esse conjunto contém valores para as variáveis independentes (entradas) e os correspondentes valores das variáveis dependentes (saídas). O processo de treinamento, quando realizado de forma supervisionada, consiste em um processo iterativo em que, a cada iteração, o conjunto de valores de entrada é processado pela rede, produzindo saídas que são, então, comparadas às saídas desejadas. Sempre que as saídas produzidas pelo modelo não correspondem, dentro de uma precisão especificada, às saídas desejadas, o conjunto de parâmetros da rede (parâmetros associados

às funções de ativação) é atualizado segundo critério que depende do algoritmo de aprendizado utilizado.

Nesta pesquisa, o treinamento da rede foi realizado de forma supervisionada por meio do algoritmo de retropropagação de erro (*error backpropagation*). Esquemáticamente, esse algoritmo pode ser resumido nos seguintes passos:

1. **Inicialização:** neste passo, selecionam-se valores iniciais para os pesos sinápticos.
2. **Apresentação dos Exemplos de Treinamento:** neste passo, apresenta-se um conjunto de exemplos de treinamento a rede. Para cada exemplo do conjunto, realiza-se a seqüência de computação para frente e para trás descritas nos passos 3 e 4 seguintes.
3. **Computação para Frente (Propagação):** supondo que um exemplo de treinamento seja representado por $(\mathbf{x}(n), \mathbf{d}(n))$, com o vetor de entrada $\mathbf{x}(n)$ aplicado à camada de entrada de nós sensoriais e o vetor de resposta desejada $\mathbf{d}(n)$ apresentado à camada de saída de nós computacionais, calculam-se os campos locais induzidos ($v_j(n)$) e os sinais funcionais da rede prosseguindo para frente através da rede, camada por camada. O campo local induzido para o neurônio j na camada l é:

$$v_j^{(l)}(n) = \sum_{i=0}^{ml} w_{ji}^{(l)}(n) y_i^{(l-1)}(n) \quad (3.24)$$

onde $y_i^{(l-1)}(n)$ é o sinal (função) de saída do neurônio i na camada anterior $l-1$, na iteração n ; e $w_{ji}^{(l)}(n)$ é o peso sináptico do neurônio j da camada l , que é alimentado pelo neurônio i da camada $l-1$. O sinal de saída do neurônio j na camada l é dado pela função de ativação, ou seja, $y_j^{(l)} = \varphi_j(v_j(n))$. Se o neurônio j está na primeira camada oculta ($l=1$), tem-se que $y_j^{(0)}(n) = x_j(n)$, onde $x_j(n)$ é o j -ésimo elemento do vetor de entrada $\mathbf{x}(n)$. Se o neurônio j está na camada de saída ($l=L$, onde L é a profundidade da rede), tem-se que $y_j^{(L)} = o_j(n)$, onde $o_j(n)$ é o j -ésimo elemento do vetor (padrão) de saída. Calcula-se, então, o sinal de erro, dado por:

$$e_j(n) = d_j(n) - o_j(n) \quad (3.25)$$

onde $d_j(n)$ é o j -ésimo elemento do vetor de resposta desejada $\mathbf{d}(n)$.

4. **Computação para Trás (Retropropagação):** este passo tem início com o cálculo dos gradientes locais da rede definidos por:

$$\delta_j^{(l)}(n) = \begin{cases} e_j^{(L)}(n) \varphi_j'(v_j^{(L)}(n)) & \text{para o neurônio } j \text{ da camada de saída } L \\ \varphi_j'(v_j^{(l)}(n)) \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) & \text{para o neurônio } j \text{ da camada oculta } l \end{cases} \quad (3.26)$$

onde o apóstrofo em $\varphi_j(\cdot)$ representa a diferenciação em relação ao argumento. Realizam-se, então, os ajustes dos pesos sinápticos da rede na camada l de acordo com a regra delta generalizada, que pode ser expressa por:

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha [w_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (3.27)$$

onde η é o parâmetro da taxa de aprendizagem e α é a constante de momento.

5. Iteração: repetem-se os passos 3 (propagação) e 4 (retropropagação), apresentando novos exemplos de treinamento à rede, até que seja satisfeito um critério de parada preestabelecido.

3.3.4.2.3 – Validação do Modelo

A validação de um modelo de redes neurais artificiais é a etapa em que a capacidade de generalização da rede utilizada é avaliada. Essa avaliação é feita utilizando um conjunto de dados diferente do conjunto utilizado no treinamento, denominado *conjunto de validação*. Quando os resultados do modelo não forem satisfatórios, segundo algum critério definido previamente, uma nova topologia para a rede, ou um novo conjunto de variáveis, ou ainda novas funções de ativação são selecionados, e o processo de treinamento é repetido.

3.3.4.3 – Modelo Híbrido: Sistema de Inferência Adaptativo Neuro-Difuso

O desenvolvimento dos modelos híbridos neuro-difusos também foi realizado em três etapas: identificação do modelo, ajuste das regras e validação do modelo. Os processos de identificação e validação do modelo foram similares aos apresentados no **item 3.3.4.1** para os modelos baseados em lógica difusa. O ajuste das regras foi realizado pelo sistema de Inferência Adaptativo Neuro-Difuso (em inglês ANFIS – *Adaptive Network Based Fuzzy Inference System*) definido por JANG (1993) representado na **Figura 2.3**.

O pacote computacional Matlab[®] possui ferramentas matemáticas que permitem a implementação do modelo ANFIS. Nessas ferramentas, o treinamento, ou seja, a obtenção dos parâmetros para as funções de pertinência, pode ser realizado por um algoritmo de retropropagação isoladamente ou pela combinação desse algoritmo com o cálculo de erros por meio de mínimos quadrados.

Para implementação do modelo ANFIS, é necessária a definição da configuração inicial de um Sistema Especialista Difuso (SED). Esta foi realizada de forma similar à apresentada no **item 3.3.4.1** para o SED do tipo *Mamdani*, tendo como ponto de partida uma análise de agrupamentos (*cluster*). Os sistemas difusos utilizados nos modelos híbridos, no entanto, foram do tipo *Takagi-Sugeno*. Os modelos testados com o SED do tipo *Takagi-Sugeno*, com treinamento pelo modelo ANFIS, foram os mesmos testados com o SED do tipo *Mamdani*, com treinamento organizativo. As funções de pertinência dos tipos triangular, trapezoidal, forma de sino e curva de Gauss foram testadas.

3.4 – SUBSÍDIOS PARA ANÁLISE

3.4.1 – CENÁRIOS HIDROLÓGICOS

As séries históricas utilizadas nesta pesquisa possuem 85 anos de dados. Visando permitir análises para diferentes situações hidrológicas, tanto de curto como de médio e longo prazo, foram definidos três tipos de cenários hidrológicos, quais sejam:

- ✓ ***Cenário de Curto Prazo:*** com 12 meses de duração;
- ✓ ***Cenário de Médio Prazo:*** com 60 meses de duração (5 anos), com início sempre em janeiro de um determinado ano;
- ✓ ***Cenário de Longo Prazo:*** com 300 meses de duração (25 anos), com início sempre em janeiro de um determinado ano.

Os cenários de curto e médio prazo foram classificados qualitativamente em *Seco*, *Normal* e *Úmido* (**Tabela 3.2**). Para os cenários de curto prazo, a classificação foi baseada no total precipitado e escoado. Já para os cenários de médio prazo, a classificação foi baseada tanto no total precipitado e escoado como no tipo de seqüência ocorrida entre os anos.

Os cenários hidrológicos de médio prazo foram utilizados para obtenção de regras operacionais e para análises comparativas. A **Tabela 3.3** apresenta o tipo de utilização de cada cenário hidrológico de médio prazo. A alocação desses cenários procurou manter a mesma proporção de secos, normais e úmidos nos subconjuntos de treinamento/ajuste de regras e de validação/análises comparativas. Os cenários de curto e de longo prazo foram utilizados exclusivamente para análises comparativas entre as metodologias.

Tabela 3.2 – Classificação dos Cenários Hidrológicos

Cenários Hidrológicos de Curto Prazo		
<i>Secos</i>		
1913; 1914; 1915; 1919; 1928; 1930; 1931; 1932; 1936; 1942; 1943; 1944; 1946; 1951; 1952; 1953; 1954; 1955; 1958; 1959; 1970; 1972; 1979; 1982; 1983; 1992; 1993		
<i>Normais</i>		
1912; 1916; 1918; 1920; 1922; 1923; 1925; 1927; 1933; 1937; 1938; 1939; 1941; 1948; 1949; 1950; 1956; 1957; 1961; 1962; 1963; 1965; 1966; 1969; 1971; 1973; 1976; 1977; 1978; 1980; 1981; 1987; 1988; 1990; 1991; 1994; 1995; 1996		
<i>Úmidos</i>		
1917; 1921; 1924; 1926; 1929; 1934; 1935; 1940; 1945; 1947; 1960; 1964; 1967; 1968; 1974; 1975; 1984; 1985; 1986; 1989		
Cenários Hidrológicos de Médio Prazo		
<i>Secos</i>		
1912 a 1916; 1927 a 1931; 1942 a 1946; 1952 a 1956; 1957 a 1961; 1992 a 1996		
<i>Normais</i>		
1917 a 1921; 1932 a 1936; 1947 a 1951; 1967 a 1971; 1972 a 1976; 1977 a 1981; 1982 a 1986; 1987 a 1991		
<i>Úmidos</i>		
1922 a 1926; 1937 a 1941; 1962 a 1966		
Cenários Hidrológicos de Longo Prazo		
1972 a 1996		

Tabela 3.3 – Tipo de Utilização dos Cenários Hidrológicos

Cenários para Treinamento e/ou Ajuste dos Modelos		
<i>Secos</i>	<i>Normais</i>	<i>Úmidos</i>
1912 a 1916; 1927 a 1931; 1942 a 1946	1917 a 1921; 1932 a 1936; 1947 a 1951; 1967 a 1971	1922 a 1926; 1937 a 1941
Cenários para Validação e/ou Análises Comparativas		
<i>Secos</i>	<i>Normais</i>	<i>Úmidos</i>
1952 a 1956; 1957 a 1961; 1992 a 1996	1972 a 1976; 1977 a 1981; 1982 a 1986; 1987 a 1991	1962 a 1966

3.4.2 – FUNÇÃO-OBJETIVO UTILIZADA NA OTIMIZAÇÃO

A estrutura da *Função-Objetivo* (FO) considerada na aplicação do modelo de programação dinâmica teve por fim minimizar os custos de abastecimento de água, os quais foram divididos em duas parcelas: custos de operação e custos devido a falhas no abastecimento, sendo este último uma penalização que, incluída na FO, faz com que o modelo de otimização evite tanto quanto possível falhas no abastecimento.

Os custos de operação são derivados dos bombeamentos do Canal do Trabalhador para o reservatório Pacajus; do reservatório Pacajus para o reservatório Pacoti; do

reservatório Pacoti/Riachão para o reservatório Gavião; e do reservatório Gavião para a Estação de Tratamento de Água (ETA). Matematicamente, pode-se expressar esses custos por:

$$CB = \alpha_{CT} . u_{CT} + \alpha_{PJ} . u_{PJ} + \alpha_{PR} . u_{PR} + \alpha_{GV} . u_{GV} \quad (3.28)$$

onde CB são os custos de operação (bombeamento), os α 's são coeficientes de custos por unidade de vazão transferida; e u_{CT} , u_{PJ} , u_{PR} e u_{GV} são, respectivamente, as vazões, em m³/s, bombeadas do Canal do Trabalhador para o reservatório Pacajus, do reservatório Pacajus para os reservatórios Pacoti/Riachão, dos reservatórios Pacoti/Riachão para o reservatório Gavião e do reservatório Gavião para a ETA.

Os custos devido a falhas no abastecimento podem ser representados matematicamente por:

$$CF = \alpha_{falha} . (Dem - u_{GV}) \quad (3.29)$$

onde CF é o custo devido a uma falha no abastecimento e Dem é a demanda, em m³/s, que deveria ter sido fornecida pelo reservatório Gavião à ETA.

A função-objetivo pode ser expressa, então, por:

$$FO = \sum_1^{t=n} CB_t + CF_t \quad (3.30)$$

onde t é um intervalo de tempo qualquer e n é o número total de intervalos de tempo.

3.4.3 – INDICADORES DE DESEMPENHO E GRAUS DE EFICIÊNCIA

Os indicadores de desempenho considerados nesta pesquisa para fins de análise comparativa podem ser agrupados em duas categorias, quais sejam:

- ✓ **Indicador de Erro:** utilizado na escolha do modelo que melhor representa cada tipo de abordagem;
- ✓ **Indicadores do Sistema Físico:** que, por indicarem características particulares do sistema físico em análise, foram utilizados apenas nas análises comparativas entre as diferentes abordagens.

O *Indicador de Erro* utilizado foi o seguinte:

- ✓ Erro Percentual Médio Absoluto:
$$EPMA = \frac{1}{N} \left[\sum_{p=1}^N |Z_c - Z_e| / Z_e \right] . 100 \quad (3.31)$$

onde: Z_c é o valor calculado; Z_e é o valor esperado oriundo do banco (biblioteca) de conhecimento; e N é o número de valores.

Os *Indicadores do Sistema Físico* utilizados foram os seguintes:

- ✓ **Indicador de Custo:** que representa os custos, em unidades monetárias, operacionais do sistema, representados matematicamente pela função de custo já apresentada;
- ✓ **Indicador de Perdas:** que representa as perdas de água ocorridas no sistema, tanto por evaporação como por vertimentos;
- ✓ **Indicadores de Garantia:** que representam a confiança no atendimento da demanda, considerando-se para análise nesta pesquisa dois indicadores: a garantia de abastecimento (porcentagem do tempo no qual a demanda foi totalmente atendida) que indica a quantidade de tempo sem racionamento ou desabastecimento; e o custo de falha, que, conforme já definido anteriormente, representa a severidade dos eventos de racionamento ou desabastecimento.

Para facilitar as comparações, foram calculados, também, graus de eficiência de custo e de perdas de cada uma das abordagens analisadas. Estes foram definidos como a relação entre o custo (perda) quando se utiliza a *Biblioteca de Conhecimentos* (valores ótimos de retiradas) e o custo (perda) da política operacional em análise. Matematicamente, tem-se:

$$GEC = (\text{custos com retiradas ótimas})/(\text{custo com a abordagem em análise}) \quad (3.32)$$

$$GEP = (\text{perdas com retiradas ótimas})/(\text{perdas com a abordagem em análise}) \quad (3.33)$$

onde GEC e GEP são os graus de eficiência nos custos e nas perdas, respectivamente. Os custos considerados para obtenção do GEC incluem tanto os custos de bombeamento como as penalizações decorrentes das falhas (custos de falha). Quanto mais próximo de zero for o grau de eficiência, pior o desempenho da política operacional em análise.

**CAPÍTULO 4 – APLICAÇÃO E RESULTADOS: APRESENTAÇÃO E
DISCUSSÃO**

4 – APLICAÇÃO E RESULTADOS

4.1 – INTRODUÇÃO

A partir do estudo de caso do sistema de reservatórios que abastece a Região Metropolitana de Fortaleza (RMF), o presente capítulo apresenta os resultados obtidos com a aplicação das metodologias descritas no Capítulo 3. Buscou-se, através de análises comparativas entre abordagens tradicionais e abordagens baseadas em inteligência artificial, inferir sobre a potencialidade destas últimas na definição de políticas operacionais para sistemas de reservatórios. O indicador de erro *EPMA – Erro Percentual Médio Absoluto* (equação 3.26) foi utilizado para a escolha do modelo que melhor representa cada tipo de abordagem. Os indicadores do sistema físico e os graus de eficiência foram utilizados nas análises comparativas entre abordagens.

A **Tabela 4.1** apresenta as abreviaturas e as descrições das variáveis de entrada utilizadas para a identificação (definição) dos modelos para os diversos tipos de abordagens testados nesta pesquisa.

Tabela 4.1 – Abreviaturas e Descrição das Variáveis de Entrada utilizadas para identificação dos modelos

Variáveis de Entrada	
Abreviatura	Descrição
VTS	Volume Total do Sistema
VPac	Volume do Açude Pacajus
VPcr	Volume dos Açudes Pacoti/Riachão
VGav	Volume do Açude Gavião
QPac	Vazão Afluyente ao Açude Pacajus
QPcr	Vazão Afluyente aos Açudes Pacoti/Riachão
QGav	Vazão Afluyente ao Açude Gavião
UCnl	Retirada do Canal do Trabalhador
UPac	Retirada do Açude Pacajus
UPcr	Retirada dos Açudes Pacoti/Riachão
UGav	Retirada do Açude Gavião
VAT	Vazão Afluyente Total ao Sistema ($VAT=QPac+QPcr+QGav$)
Previsão	Variável que caracteriza a previsão climática
Estação	Variável que caracteriza a Estação do Ano

4.2 – A BIBLIOTECA DE CONHECIMENTOS: COMPOSIÇÃO E INDICADORES DE DESEMPENHO

A *Biblioteca de Conhecimentos* (Base de Dados) utilizada na obtenção das políticas operacionais pelos diversos tipos de abordagem foi obtida por meio de Programação

Dinâmica Incremental (PDI). Visando permitir análises para diferentes situações hidrológicas e tendo em vista a “maldição” da dimensionalidade presente em algoritmos de programação dinâmica, as séries históricas foram divididas em subséries – 17 no total – de 5 anos (60 meses), representativas dos cenários hidrológicos de médio prazo. Os valores ótimos das retiradas para essas 17 subséries, e que em conjunto formam a *Biblioteca de Conhecimentos*, estão apresentados no **Anexo I**.

Utilizando a classificação dos cenários hidrológicos apresentada nas **Tabelas 3.2 e 3.3**, a **Tabela 4.2** mostra, tendo por base a *Biblioteca de Conhecimentos*, os valores dos indicadores do sistema físico para os cenários de médio prazo que foram utilizados para comparação entre as técnicas.

Tabela 4.2 – Indicadores do Sistema Físico baseados na Biblioteca de Conhecimentos – Cenários de Médio Prazo para Comparação

Cenários Hidrológicos		Indicadores do Sistema Físico				
		Indicador de Custo (Unidade Monetária)	Indicadores de Garantia		Indicador de Perdas (hm ³)	
Tipo	Anos	Custo de Bombeamento	Garantia (%)	Custo de Falha		
Médio Prazo	Seco	1957 a 1961	5,3247	100,00	0,0000	3042,40
	Normal	1972 a 1976	4,8887	100,00	0,0000	6156,40
	Úmido	1962 a 1966	3,6346	100,00	0,0000	5696,30
	Valores Médios		4,6160	100,00	0,0000	4965,03

4.3 – A POLÍTICA OPERACIONAL HEURÍSTICA

A Política Operacional Heurística (POH) implementada nesta pesquisa é a apresentada nas **equações 3.13** que consideram o conceito de volume de alerta. Esse tipo de política operacional tem sido largamente utilizado no Nordeste semi-árido, sendo importante, portanto, a comparação entre os resultados obtidos com ela com aqueles obtidos pelos demais tipos de abordagem. A **Tabela 4.3** apresenta os indicadores de desempenho do sistema físico e os graus de eficiência de custos e perdas com a utilização da POH.

A operação por meio da POH resultou, quando comparada à operação ótima para os cenários de médio prazo, aumento médio de 158% nos custos (grau de eficiência igual a 0,387) e de 62 hm³ por ano nas perdas, valor suficiente para o atendimento de quatro meses da demanda do sistema em análise.

Tabela 4.3 – Indicadores do Sistema Físico e Graus de Eficiência da Política Operacional Heurística – Cenários de Comparação

Cenários Hidrológicos Analisados		Indicadores do Sistema Físico					Graus de Eficiência ³	
		Indicador de Custo (Unidade Monetária)	Indicadores de Garantia		Indicador de Perdas (hm ³)			
Tipo	Anos	Custo de Bombeamento	Garantia (%)	Custo de Falha		Custos	Perdas	
Curto Prazo	Seco	1992	2,2500	100,00	0,00	146,10		
	Normal	1987	2,2500	100,00	0,00	144,64		
	Úmido	1964	2,2500	100,00	0,00	2576,40		
	Valores Médios		2,2500	100,00	0,00	955,71		
Médio Prazo	Seco	1957 a 1961	11,5875	100,00	0,00	3409,80	0,460	0,892
	Normal	1972 a 1976	12,4875	100,00	0,00	6429,30	0,391	0,958
	Úmido	1962 a 1966	11,7000	100,00	0,00	5998,40	0,311	0,950
	Valores Médios		11,9250	100,00	0,00	5279,17	0,387	0,933
Longo Prazo	1972 a 1996	63,3750	100,00	0,00	19765,00			

A razão para isso é que uma POH, além de ser pouco flexível, é geralmente concebida de forma conservadora, ou seja, planeja-se bombear um maior volume de água com receio da ocorrência de uma seca, tendo-se um maior custo de operação e aumentando as perdas por vertimento se esta não se confirmar. A observação dos resultados para os cenários de curto prazo confirma essa afirmação. Para cenários distintos, os custos de bombeamentos são iguais (pouca flexibilidade da POH) mesmo com perdas significativamente elevadas, particularmente para o período úmido (elevado conservadorismo da POH).

4.4 – AS ABORDAGENS TRADICIONAIS

4.4.1 – MODELOS BASEADOS EM ANÁLISE DE REGRESSÃO (PDIR)

Os modelos baseados em análise de regressão que foram testados, seguindo a formulação geral apresentada nas equações 3.14, estão apresentados na Tabela 4.4. Para considerar o efeito da sazonalidade, o modelo com melhor resultado, ou seja, com menor EPMA, foi novamente ajustado, considerando, no entanto, duas equações: uma para a estação chuvosa (janeiro a julho) e outra para a estação seca (julho a dezembro). A Tabela 4.5 apresenta os valores de EPMA obtidos.

³ Os graus de eficiência foram calculados somente em relação aos cenários de médio prazo já que o algoritmo de otimização foi aplicado apenas a esses cenários.

Tabela 4.4 – Modelos Matemáticos para Análises de Regressão

Identificação do Modelo	Variáveis Independentes					
M01Reg	VPac _t	VPcr _t	VGav _t			
M02Reg	VTS _t	QPac _{t-1}	QPcr _{t-1}	QGav _{t-1}		
M03Reg	VPac _t	VPcr _t	VGav _t	QPac _{t-1}	QPcr _{t-1}	QGav _{t-1}
M04Reg	VPac _t	VPcr _t	VGav _t	UCnl _{t-1}	UPac _{t-1}	UPcr _{t-1}

Tabela 4.5 – Indicador de Desempenho – Modelos baseados em Análise de Regressão

Modelo	Erro Percentual Médio Absoluto (EPMA)							
	Valores Médios		Valores Individualizados					
			Pacoti/Riachão		Pacajus		Canal do Trabalhador	
	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação
M01Reg	23,49	22,91	11,89	13,33	33,40	29,65	25,18	25,76
M02Reg	23,05	22,12	11,21	12,13	33,72	29,75	24,23	24,49
M03Reg	22,63	21,87	11,16	12,04	33,01	29,29	23,72	24,30
M04Reg	14,31	15,39	11,08	12,41	13,77	13,99	18,07	19,79
MRegS	13,53	14,92	10,00	11,37	13,68	13,81	16,91	19,59

Da análise da **Tabela 4.5**, constata-se que o M04Reg apresenta o menor valor de EPMA. A inclusão da sazonalidade nesse modelo propiciou uma diminuição de 5% no valor médio do indicador de erro. O modelo M04Reg considerando o efeito da sazonalidade, representado por MRegS, foi, portanto, selecionado como representativo desse tipo de abordagem para comparação com as demais. A **Tabela 4.6** apresenta os indicadores de desempenho do sistema físico e os graus de eficiência de custos e perdas resultantes desse modelo.

A operação por meio da política operacional oriunda da análise de regressão realizada com os resultados da otimização (POR) resultou em custo médio de 79% mais elevado (grau de eficiência igual a 0,558) quando comparada à operação ótima para os cenários de médio prazo. As perdas foram incrementadas, em média, 31,6 hm³/ano, valor equivalente a dois meses de atendimento da demanda. Da análise dos resultados para os cenários de curto prazo, constatou-se que, diferentemente da POH, a POR é mais flexível e tenta embutir nas equações a busca da operação ótima, permitindo a diminuição dos custos e das perdas. No período úmido analisado, para o mesmo nível de atendimento da demanda, os custos com a POR foram 56% inferiores aos da POH.

Tabela 4.6 – Indicadores do Sistema Físico e Graus de Eficiência do Modelo baseado em Análise de Regressão – Cenários de Comparação

Cenários Hidrológicos Analisados		Indicadores do Sistema Físico					Graus de Eficiência ³	
		Indicador de Custo (Unidade Monetária)	Indicadores de Garantia		Indicador de Perdas (hm ³)			
Tipo	Anos	Custo de Bombeamento	Garantia (%)	Custo de Falha		Custos	Perdas	
Curto Prazo	Seco	1992	1,8546	100,00	0,00	140,55		
	Normal	1987	1,7211	100,00	0,00	124,12		
	Úmido	1964	0,9772	100,00	0,00	2534,10		
	Valores Médios		1,5176	100,00	0,00	932,92		
Médio Prazo	Seco	1957 a 1961	9,4269	100,00	0,00	3268,30	0,565	0,931
	Normal	1972 a 1976	7,7195	100,00	0,00	6223,90	0,633	0,989
	Úmido	1962 a 1966	7,6353	100,00	0,00	5877,80	0,476	0,969
	Valores Médios		8,2606	100,00	0,00	5123,33	0,558	0,963
Longo Prazo	1972 a 1996	42,3443	100,00	0,0000	18899,00			

4.4.2 – MODELO BASEADO EM ZONEAMENTO DOS RESERVATÓRIOS (PDIZ)

O modelo baseado em zoneamento dos reservatórios seguiu o esquema geral apresentado na **Figura 3.13**. As **Figuras 4.1 a 4.3** mostram os histogramas mensais de frequência utilizados na elaboração dos zoneamentos. Esses foram obtidos por intermédio da divisão, em classes de vazões, dos valores ótimos das retiradas obtidos com as 17 subséries de médio prazo, conforme metodologia já discutida anteriormente. A **Tabela 4.7** apresenta os indicadores de desempenho do sistema físico e os graus de eficiência de custos e perdas resultantes dessa abordagem.

Tabela 4.7 – Indicadores do Sistema Físico e Graus de Eficiência do Modelo baseado em Zoneamento dos Reservatórios – Cenários de Comparação

Cenários Hidrológicos Analisados		Indicadores do Sistema Físico					Graus de Eficiência ³	
		Indicador de Custo (Unidade Monetária)	Indicadores de Garantia		Indicador de Perdas (hm ³)			
Tipo	Anos	Custo de Bombeamento	Garantia (%)	Custo de Falha		Custos	Perdas	
Curto Prazo	Seco	1992	1,9350	100,00	0,00	135,91		
	Normal	1987	1,9800	100,00	0,00	120,19		
	Úmido	1964	1,3200	100,00	0,00	2548,00		
	Valores Médios		1,7450	100,00	0,00	934,70		
Médio Prazo	Seco	1957 a 1961	6,6450	100,00	0,00	3077,00	0,801	0,989
	Normal	1972 a 1976	5,8650	100,00	0,00	6071,50	0,834	1,014
	Úmido	1962 a 1966	7,3350	100,00	0,00	5815,80	0,496	0,979
	Valores Médios		6,6150	100,00	0,00	4988,10	0,710	0,994
Longo Prazo	1972 a 1996	42,3750	100,00	0,00	18507,00			

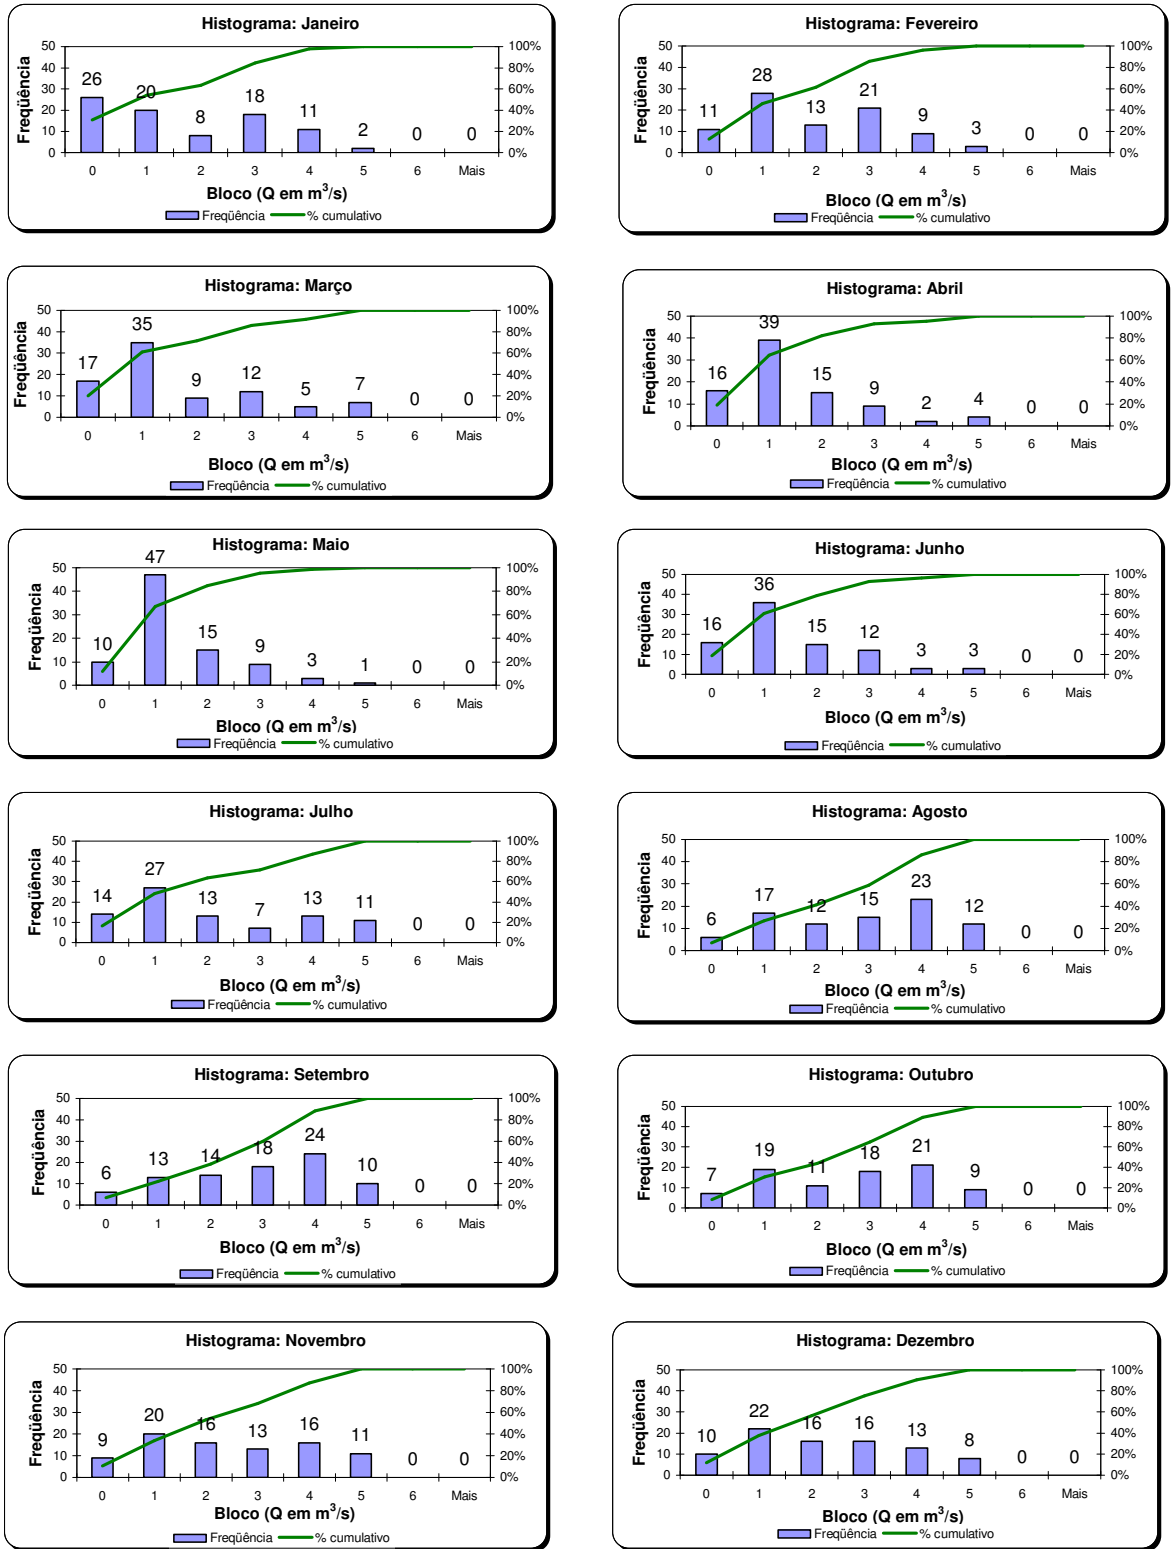


Figura 4.1 – Histogramas Mensais de Frequência da Transferência de Água do Canal do Trabalhador para o Reservatório Pacajus

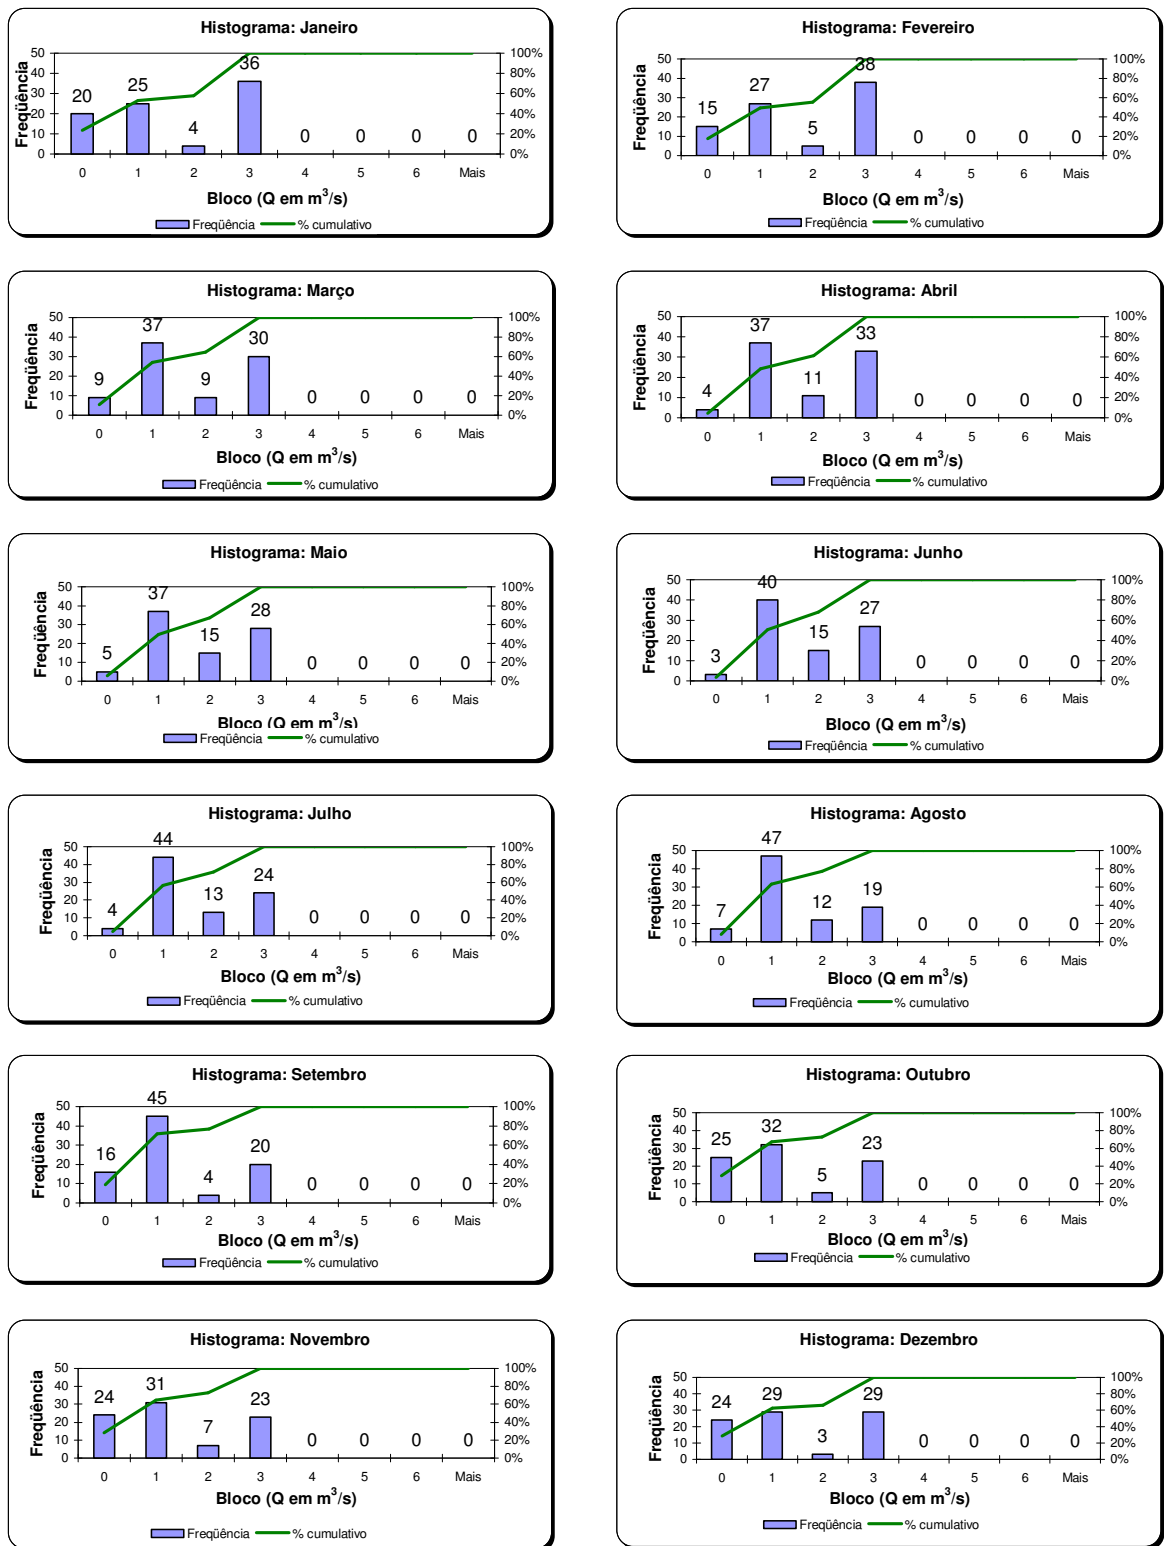


Figura 4.2 – Histogramas Mensais de Frequência da Transferência de Água do Reservatório Pacajus para os Reservatórios Pacotí/Riachão















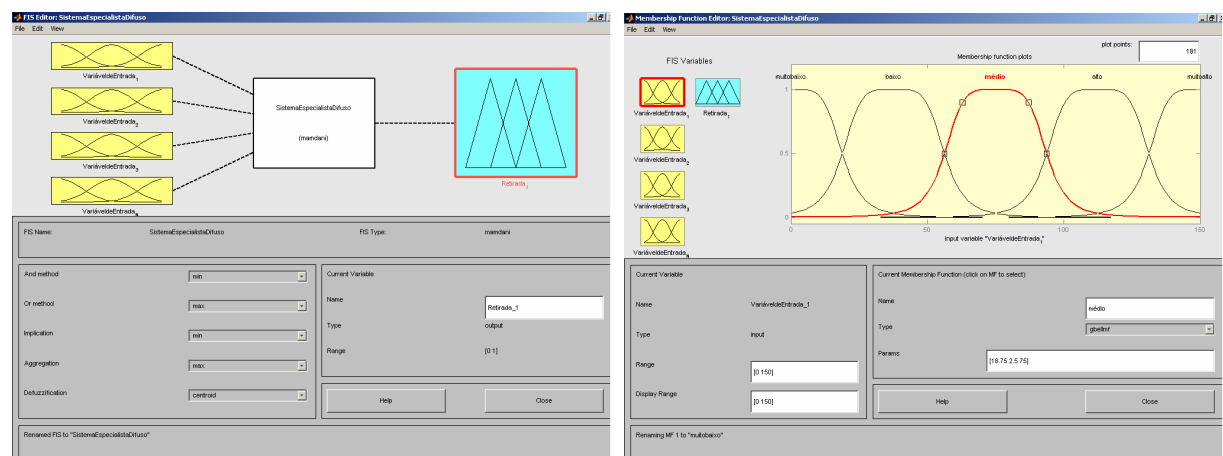
Figura 4.3 – Histogramas Mensais de Frequência da Transferência de Água dos Reservatórios Pacoti/Riachão para o Reservatório Gavião

A operação por intermédio da política operacional oriunda do zoneamento dos reservatórios (POZ) mostrou-se mais eficiente que as demais abordagens tradicionais – POH e POR – do ponto de vista dos custos, resultando em custo médio 43% mais elevado (grau de eficiência igual a 0,710) quando comparada à operação ótima para os cenários de médio prazo. Do ponto de vista da flexibilidade, no entanto, por dividir os reservatórios em grandes zonas, atribuindo a cada uma dessas zonas valores fixos de vazão, a POZ apresentou resultados inferiores aos da POR, ocasionando, nos cenários de curto prazo, custos maiores, com diferença mais acentuada no período úmido. A POZ mostrou-se, também, bastante eficiente do ponto de vista das perdas, apresentando valores similares àqueles resultantes da operação ótima com minimização dos custos.

4.5 – AS ABORDAGENS BASEADAS EM INTELIGÊNCIA ARTIFICIAL

4.5.1 – MODELOS BASEADOS EM LÓGICA DIFUSA (PDID)

Os modelos baseados em lógica difusa foram obtidos, conforme descrito no Capítulo 3, em três etapas: identificação dos modelos, treinamento (ou ajuste das regras) e validação. Em virtude da dimensão do problema em análise, relativamente elevada, a modelagem para as retiradas foi realizada de forma individualizada, ou seja, obteve-se um Sistema Especialista Difuso (SED) para cada uma das retiradas. A **Figura 4.4** apresenta o esquema geral dos SEDs utilizados.



(a) Configuração Geral do Sistema Especialista Difuso

(b) Definição das Funções de Pertinência

Figura 4.4 – Esquema Geral dos Sistemas Especialistas Difusos utilizados

A **Tabela 4.8** apresenta o processo de identificação dos modelos. Nesta tabela, os modelos estão divididos em três grupos, quais sejam:

- ✓ **Modelos Quantitativos:** aqueles que incluem apenas variáveis representativas das características físicas do sistema em análise, tais como volumes dos reservatórios e do sistema, vazões afluentes e retiradas;
- ✓ **Modelos Quantitativos-Sazonais:** que incluem, além das variáveis quantitativas, variável de identificação da estação do ano;
- ✓ **Modelos Quali-Quantitativos:** que incluem, além das variáveis anteriores, variável que permite a previsão, do ponto de vista qualitativo (semântico) e em relação à quantidade de precipitação, da estação ou do mês seguinte.

Tabela 4.8 – Modelos de Sistemas Especialistas Difusos

Identificação do Modelo	Variáveis Antecedentes
<i>Modelos Quantitativos</i>	
MBaseSED	VTS_t
M01SED	$VPac_t \quad VPcr_t \quad VGav_t$
M02SED	$VPac_t \quad VPac_{t-1} \quad VPcr_t \quad VPcr_{t-1} \quad VGav_t \quad VGav_{t-1}$
M03SED	$VTS_t \quad VTS_{t-1} \quad QPac_{t-1} \quad QPcr_{t-1}$
M04SED	$VTS_t \quad VTS_{t-1} \quad QPac_{t-1} \quad QPac_{t-2} \quad QPcr_{t-1} \quad QPcr_{t-2}$
M05SED	$VPac_t \quad VPcr_t \quad QPac_{t-1} \quad QPcr_{t-1}$
M06SED	$VPac_t \quad VPcr_t \quad QPac_{t-1} \quad QPac_{t-2} \quad QPcr_{t-1} \quad QPcr_{t-2}$
M07SED	$VTS_t \quad UCnl_{t-1} \quad UPac_{t-1} \quad UPcr_{t-1}$
M08SED	$VTS_t \quad UCnl_{t-1} \quad UPac_{t-1} \quad UPcr_{t-1} \quad QPac_{t-1} \quad QPcr_{t-1}$
M09SED	$VPac_t \quad VPcr_t \quad UCnl_{t-1} \quad UPac_{t-1} \quad UPcr_{t-1}$
M10SED	$VTS_t \quad \text{Vazão Afluente Total (VAT)}_{t-1} \quad (\text{VAT} = \text{QPac} + \text{QPcr} + \text{QGav})$
<i>Modelos Quantitativo-Sazonais</i>	
MBase_s_SED	MBaseSED + Estação em (t) com 3 categorias (seca, intermediária e chuvosa)
M01sSED	Melhor entre M01 e M10 + Estação em (t) com 3 categorias (seca, intermediária e chuvosa)
<i>Modelo Quali-Quantitativo</i>	
M01qSED	Melhor entre M01 e M10 e M01s + Previsão da Estação seguinte (seca; normal e úmida), baseada no valor da precipitação anual P_{anual}
M02qSED	Melhor entre M01 e M10 e M01s + Previsão do Mês seguinte (abaixo da média; normal e acima da média), baseada no valor da precipitação mensal

Modelos identificados como *Base* (*MBaseSED* e *MBase_s_SED*) foram utilizados de forma combinada com os demais modelos. Para as situações em que o modelo mais complexo não continha uma regra, o *Modelo Base* era acionado automaticamente, agindo de forma combinada (*Modelos Hierarquicamente Escalonados*) para obtenção dos valores da variável conseqüente. A **Figura 4.5** ilustra este processo. Essa estratégia evitou a Falta de Conhecimento, problema comum em Sistemas Especialistas Difusos.

Se existe pelo menos uma regra para a condição atual, faça: Executa regra do modelo mais complexo Senão: Executa Modelo Base (com menor número de antecedentes) Fim se;

Figura 4.5 – Esquema de utilização dos Modelos Hierarquicamente Escalonados

Ainda no processo de identificação dos modelos, é necessária a partição das variáveis. Dois são os procedimentos possíveis: a análise dos agrupamentos difusos e a partição arbitrária. Pelas características do sistema em análise, com complexas relações resultante do número de variáveis envolvidas, optou-se nesta pesquisa pela partição utilizando métodos de agrupamento para reconhecimento de padrões. Uma partição uniforme com análise heurística resultaria um número maior de conjuntos difusos, aumentando a dimensionalidade do problema. Além disso, corrobora com esta opção o fato dos volumes dos reservatórios e os valores das vazões afluentes e das retiradas estarem relacionados uns com os outros para um determinado intervalo de tempo, não podendo ocupar combinações completamente aleatórias nos universos de domínio.

Conforme descrito no Capítulo 3, três indicadores – o Índice de Validade (V_d), o Coeficiente de Partição Difusa (P_d) e o Coeficiente de Partição Difusa Significativa (P_{dsig}) – foram utilizados na escolha do melhor número de conjuntos difusos para as variáveis antecedentes e conseqüentes. O **Anexo II** apresenta os valores de V_d , P_d e P_{dsig} para os diversos modelos. A **Tabela 4.9** apresenta o número de conjuntos difusos adotados para os modelos quantitativos apresentados na **Tabela 4.8**. Para as variáveis quantitativas dos modelos quantitativo-sazonais e quali-quantitativos, foi utilizado o mesmo número de partições do modelo quantitativo correspondente. As variáveis que representam a sazonalidade e a previsão tiveram a partição realizada em três conjuntos difusos.

A segunda etapa da modelagem, ou seja, a obtenção das regras dos sistemas especialistas difusos para cada um dos modelos, foi realizada de duas formas, quais sejam:

- ✓ **Forma Heurística:** neste caso, após a partição das variáveis decorrente da análise de agrupamentos, gerou-se, de forma heurística, uma regra a partir de cada um dos protótipos (centros dos conjuntos difusos) obtidos;
- ✓ **Por Treinamento Organizativo:** neste caso, utilizando também a partição das variáveis decorrente da análise de agrupamentos, as regras foram obtidas a partir do processo de aprendizagem difusa denominado treinamento organizativo, conforme descrito no Capítulo 3.

Tabela 4.9 – Número de Agrupamentos Difusos – Modelos Quantitativos de Sistemas Especialistas Difusos

Modelo	Número de Conjuntos Difusos (c)		
	SED para a retirada dos açúdes Pacoti/Riachão	SED para a retirada do açúde Pacajus	SED para a retirada do Canal do Trabalhador
MBaseSED	9	7	8
M01SED	8	6	7
M02SED	7	6	8
M03SED	6	7	9
M04SED	6	7	7
M05SED	5	8	6
M06SED	5	8	5
M07SED	4	6	4
M08SED	5	6	5
M09SED	6	6	6
M10SED	5	6	8

As Tabelas 4.10 e 4.11 apresentam, para os modelos quantitativos, os *Erros Percentuais Médios Absolutos* (EPMA) obtidos com os Sistemas Especialistas Difusos, respectivamente para os SEDs com regras heurísticas e para os SEDs com regras obtidas por treinamento organizativo.

Tabela 4.10 – Indicador de Desempenho – Modelos baseados em Lógica Difusa – SEDs com Regras Heurísticas – Modelos Quantitativos

Modelo	Erro Percentual Médio Absoluto (EPMA)							
	Valores Médios		Valores Individualizados					
	Ajuste	Validação	Pacoti/Riachão		Pacajus		Canal do Trabalhador	
	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação
MBaseSED	26,51	26,89	14,45	16,10	38,00	35,64	27,08	28,92
M01SED	31,26	29,47	14,40	15,79	46,71	38,57	32,67	34,04
M02SED	22,75	24,90	12,00	13,76	28,26	30,97	28,00	29,97
M03SED	29,11	27,62	13,79	16,02	49,56	42,73	23,98	24,11
M04SED	25,44	26,28	13,92	17,10	39,25	38,30	23,17	23,46
M05SED	23,59	23,09	11,67	12,71	34,31	30,74	24,79	25,82
M06SED	22,95	23,19	11,99	13,00	33,14	31,11	23,73	25,45
M07SED	19,11	19,73	11,44	13,22	24,03	22,54	21,87	23,42
M08SED	19,65	19,99	12,01	13,62	24,29	23,57	22,66	22,78
M09SED	19,23	20,34	11,69	13,29	23,34	23,21	22,66	24,51
M10SED	23,34	23,14	11,54	12,51	32,49	28,32	26,00	28,58

Essas tabelas apresentam os EPMA tanto para os conjuntos de ajuste das regras como para os de validação (terceira etapa da modelagem). Os resultados indicam uma equivalência entre os valores obtidos para os dois tipos de conjunto, podendo-se afirmar que a capacidade de generalização dos SEDs, ou seja, de obter resultados satisfatórios para um conjunto de dados não utilizados na fase de ajuste (treinamento), é adequada. Ainda da análise das

Tabelas 4.10 e 4.11, percebe-se, com clareza, que os SEDs com regras obtidas por treinamento organizativo têm desempenhos superiores aos seus correspondentes com regras heurísticas. Em média, o EPMA é 23% menor. As análises que seguem, portanto, foram elaboradas apenas com os SEDs com regras obtidas por treinamento organizativo.

Tabela 4.11 – Indicador de Desempenho – Modelos baseados em Lógica Difusa – SEDs com Regras obtidas por Treinamento Organizativo – Modelos Quantitativos

Modelo	Erro Percentual Médio Absoluto (EPMA)							
	Valores Médios		Valores Individualizados					
	Ajuste	Validação	Pacoti/Riachão		Pacajus		Canal do Trabalhador	
	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação
MBaseSED	20,23	21,35	11,70	13,73	25,76	25,07	23,22	25,26
M01SED	19,76	23,22	9,92	15,36	28,53	27,56	20,82	26,74
M02SED	18,42	24,19	7,48	14,21	30,13	33,67	17,66	24,70
M03SED	20,70	21,29	11,07	12,52	29,47	26,45	21,54	24,90
M04SED	19,59	21,77	10,95	12,94	26,51	28,00	21,31	24,36
M05SED	19,29	21,72	10,85	12,54	26,12	26,32	20,91	26,31
M06SED	19,45	21,90	10,48	12,72	25,77	28,32	22,09	24,66
M07SED	15,30	18,89	11,48	13,92	14,83	18,43	19,59	24,32
M08SED	14,30	18,80	9,74	13,31	14,96	19,45	18,19	23,66
M09SED	12,99	19,36	8,27	14,28	13,68	18,33	17,01	25,48
M10SED	20,80	21,59	10,92	12,12	27,90	26,58	23,56	26,06

Na montagem dos modelos quantitativo-sazonais foram utilizados os modelos quantitativos com melhores resultados. Como as variáveis conseqüentes (retiradas) foram modeladas de forma individualizada, tendo em vista a dimensionalidade dos problemas, o conjunto de variáveis antecedentes que gera o melhor *Sistema Especialista Difuso* foi diferente para cada uma das variáveis conseqüentes modeladas. Tendo por base os resultados de EPMA apresentados na **Tabela 4.11**, a **Tabela 4.12** apresenta os melhores modelos quantitativos para cada uma das variáveis conseqüentes e os seus respectivos antecedentes. A incorporação da sazonalidade foi realizada, portanto, para cada um desses modelos, considerando, como já explicitado anteriormente, a variável *Estação* com uma partição em três categorias (seca, intermediária e chuvosa) e as demais variáveis com o mesmo número de partições do modelo correspondente sem sazonalidade.

Tabela 4.12 – Modelos baseados em Lógica Difusa – Modelos Quantitativo-Sazonais Adotados

Variável de Saída (Conseqüente)	Melhor Modelo (Quantitativo)	
	Código	Antecedentes
Retirada dos Açúdes Pacoti/Riachão (uPcr)	M10SED	VTS_t Vazão Afluente Total (VAT) $_{t-1}$
Retirada do Açude Pacajus (uPac)	M09SED	$VPac_t$ $VPcr_t$ $UCnl_{t-1}$ $UPac_{t-1}$ $UPcr_{t-1}$
Retirada do Canal do Trabalhador (uCnl)	M08SED	VTS_t $UCnl_{t-1}$ $UPac_{t-1}$ $UPcr_{t-1}$ $QPac_{t-1}$ $QPcr_{t-1}$

A **Tabela 4.13** apresenta, para os modelos quantitativo-sazonais, os *Erros Percentuais Médios Absolutos (EPMA)* obtidos. Observa-se que a inclusão da sazonalidade melhorou os resultados para os SEDs que representam as retiradas dos açudes Pacoti/Riachão (redução de 5% no EPMA) e do Canal do Trabalhador (redução de 8% no EPMA). Para a retirada do açude Pacajus, o modelo exclusivamente quantitativo teve desempenho superior.

Tabela 4.13 – Indicador de Desempenho – Modelos baseados em Lógica Difusa – Modelos Quantitativo-Sazonais

Modelo	Erro Percentual Médio Absoluto (EPMA)							
	Valores Médios		Valores Individualizados					
	Ajuste	Validação	Pacoti/Riachão		Pacajus		Canal do Trabalhador	
			Ajuste	Validação	Ajuste	Validação	Ajuste	Validação
MBase_s_SED	19,93	21,29	10,63	12,64	28,24	25,97	20,92	25,26
M01sSED	13,94	18,51	10,38	11,92	14,69	20,02	16,75	23,59

Na montagem dos modelos quali-quantitativos foram utilizados os modelos quantitativos e quantitativo-sazonais com melhores resultados. A **Tabela 4.14** apresenta os melhores modelos para cada uma das variáveis conseqüentes e os seus respectivos antecedentes. A incorporação da *Previsão Climática* foi realizada considerando a variável *Previsão* com uma partição em três categorias. Para as demais variáveis, foi utilizado o mesmo número de partições do modelo correspondente.

Tabela 4.14 – Modelos baseados em Lógica Difusa – Modelos Quali-Quantitativos Adotados

Variável de Saída (Conseqüente)	Melhor Modelo (Quantitativo ou Quantitativo-Sazonal)	
	Código	Antecedentes
Retirada dos Açudes Pacoti/Riachão (uPcr)	M01sSED	VTS_t Vazão Afluentes Total (VAT) $_{t-1}$ Estação $_t$
Retirada do Açude Pacajus (uPac)	M09SED	$VPac_t$ $VPcr_t$ $UCnl_{t-1}$ $UPac_{t-1}$ $UPcr_{t-1}$
Retirada do Canal do Trabalhador (uCnl)	M01sSED	VTS_t $UCnl_{t-1}$ $UPac_{t-1}$ $UPcr_{t-1}$ $QPac_{t-1}$ $QPcr_{t-1}$ Estação $_t$

A **Tabela 4.15** apresenta, para os modelos quali-quantitativos, os *Erros Percentuais Médios Absolutos (EPMA)* obtidos. A inclusão de uma variável de previsão melhorou os resultados em todos os casos, reduzindo os EPMA em 5,9%, 14,4% e 15,8% respectivamente para os SEDs das retiradas dos açudes Pacoti/Riachão, do açude Pacajus e do Canal do Trabalhador, com a utilização do modelo M02qSED.

Tabela 4.15 – Indicador de Desempenho – Modelos baseados em Lógica Difusa – Modelos Quali-Quantitativos

Modelo	Erro Percentual Médio Absoluto (EPMA)							
	Valores Médios		Valores Individualizados					
	Ajuste	Validação	Pacoti/Riachão		Pacajus		Canal do Trabalhador	
Ajuste			Validação	Ajuste	Validação	Ajuste	Validação	
M01qSED	12,19	18,93	9,96	11,86	12,03	21,23	14,58	23,70
M02qSED	11,86	17,65	9,77	11,18	11,71	18,88	14,10	22,88

Do exposto, conclui-se que o modelo com melhores resultados, e que será utilizado como representativo desse tipo de abordagem para comparação com as demais, é o modelo *M02qSED*. Destaque-se, no entanto, que nesta definição, foram utilizadas, em todos os casos, funções de pertinência do tipo triangular. Visando verificar a possibilidade de melhoria do desempenho deste modelo, outros três tipos de funções de pertinência – trapezoidal, forma de sino e curva de Gauss – foram testados. A **Tabela 4.16** apresenta os valores de EPMA considerando diferentes funções de pertinência.

Tabela 4.16 – Análise do uso de diferentes tipos de Funções de Pertinência – Modelo baseado em Lógica Difusa

Tipo de Função de Pertinência	Erro Percentual Médio Absoluto (EPMA)			
	Valores Médios	SED para a retirada dos açudes Pacoti/Riachão	SED para a retirada do açude Pacajus	SED para a retirada do Canal do Trabalhador
Triangular	11,86	9,77	11,71	14,10
Trapezoidal	10,50	9,61	9,75	12,15
Forma de Sino	12,02	9,60	12,65	13,81
Curva de Gauss	14,30	9,78	16,15	16,96
Variação % - Maior/Menor	35,67%	1,86%	65,55%	39,61%

A análise da **Tabela 4.16** indica que a escolha do tipo de função de pertinência tem grande impacto nos resultados. A diferença média no EPMA entre o melhor (função de pertinência tipo trapezoidal) e o pior (função de pertinência tipo curva de Gauss) resultado foi de 35%. Devido à superioridade no desempenho, o modelo *M02qSED* com função de pertinência tipo trapezoidal foi utilizado nas análises comparativas desta pesquisa. A **Tabela 4.17** apresenta os indicadores de desempenho do sistema físico e os graus de eficiência de custos e perdas resultantes deste modelo.

A operação por meio da política operacional oriunda do Sistema Especialista Difuso (SED) mostrou-se bem mais eficiente que as abordagens tradicionais – POH, POR e POZ – do ponto de vista dos custos, resultando em custos apenas 11 % mais elevados (grau de

eficiência igual a 0,900) quando comparada à operação ótima para os cenários de médio prazo. Isso decorre do fato desse tipo de operação aliar flexibilidade – permite a adoção de qualquer valor de retirada dentro do universo de domínio das variáveis – com a capacidade de extrair maior e melhor informação da *Biblioteca de Conhecimentos* utilizada. Do ponto de vista das perdas, a operação com o SED também se mostrou bastante eficiente, com valores próximos àqueles resultantes da operação ótima com minimização dos custos. Uma análise comparativa mais detalhada com as demais técnicas está apresentada em item específico desta tese.

Tabela 4.17 – Indicadores do Sistema Físico e Graus de Eficiência do Modelo baseado em Lógica Difusa – Cenários de Comparação

Cenários Hidrológicos Analisados		Indicadores do Sistema Físico					Graus de Eficiência ³	
		Indicador de Custo (Unidade Monetária)	Indicadores de Garantia		Indicador de Perdas (hm ³)			
Tipo	Anos	Custo de Bombeamento	Garantia (%)	Custo de Falha		Custos	Perdas	
Curto Prazo	Seco	1992	0,9570	100,00	0,00	105,91		
	Normal	1987	1,2039	100,00	0,00	121,72		
	Úmido	1964	0,8919	100,00	0,00	2539,10		
	Valores Médios		1,0176	100,00	0,00	922,24		
Médio Prazo	Seco	1957 a 1961	6,1955	100,00	0,00	3180,60	0,859	0,957
	Normal	1972 a 1976	5,0571	100,00	0,00	6131,60	0,967	1,004
	Úmido	1962 a 1966	4,1637	100,00	0,00	5783,80	0,873	0,985
	Valores Médios		5,1388	100,00	0,00	5032,00	0,900	0,982
Longo Prazo	1972 a 1996	27,1270	100,00	0,00	18267,00			

4.5.2 – MODELOS BASEADOS EM REDES NEURAS ARTIFICIAIS (PDIN)

Os modelos baseados em redes neurais artificiais também foram obtidos, conforme descrito no Capítulo 3, em três etapas: identificação dos modelos, treinamento e validação. A **Figura 4.6** apresenta o esquema geral das redes neurais artificiais utilizadas. A camada de saída possui três nós indicados por uPcr (retirada dos açudes Pacoti/Riachão), uPac (retirada do açude Pacajus) e uCnl (retirada do Canal do Trabalhador). A camada de entrada tem tantos nós quantos forem os sinais (variáveis) de entrada decorrentes do processo de identificação dos modelos. A **Tabela 4.18** apresenta esse processo. Nessa tabela, assim como naquela que apresenta os modelos baseados em lógica difusa, há uma divisão em três tipos de modelos, quais sejam: quantitativos, quantitativo-sazonais e quali-quantitativos.




Figura 4.6 – Esquema Geral das Redes Neurais Artificiais utilizadas

Tabela 4.18 – Modelos de Redes Neurais Artificiais

Identificação do Modelo	Variáveis (Sinais) de Entrada
<i>Modelos Quantitativos</i>	
M01RNA	$VPac_t$ $VPcr_t$ $VGav_t$
M02RNA	$VPac_t$ $VPac_{t-1}$ $VPcr_t$ $VPcr_{t-1}$ $VGav_t$ $VGav_{t-1}$
M03RNA	VTS_t VTS_{t-1} $QPac_{t-1}$ $QPcr_{t-1}$ $QGav_{t-1}$
M04RNA	VTS_t VTS_{t-1} $QPac_{t-1}$ $QPac_{t-2}$ $QPcr_{t-1}$ $QPcr_{t-2}$ $QGav_{t-1}$ $QGav_{t-2}$
M05RNA	$VPac_t$ $VPcr_t$ $VGav_t$ $QPac_{t-1}$ $QPcr_{t-1}$ $QGav_{t-1}$
M06RNA	$VPac_t$ $VPcr_t$ $VGav_t$ $QPac_{t-1}$ $QPac_{t-2}$ $QPcr_{t-1}$ $QPcr_{t-2}$ $QGav_{t-1}$ $QGav_{t-2}$
M07RNA	$VPac_t$ $VPac_{t-1}$ $VPcr_t$ $VPcr_{t-1}$ $VGav_t$ $VGav_{t-1}$ $QPac_{t-1}$ $QPac_{t-2}$ $QPcr_{t-1}$ $QPcr_{t-2}$ $QGav_{t-1}$ $QGav_{t-2}$
M08RNA	VTS_t VTS_{t-1} $UCnl_{t-1}$ $UPac_{t-1}$ $UPcr_{t-1}$ $UGav_{t-1}$ $QPac_{t-1}$ $QPcr_{t-1}$ $QGav_{t-1}$
M09RNA	$VPac_t$ $VPcr_t$ $VGav_t$ $UCnl_{t-1}$ $UPac_{t-1}$ $UPcr_{t-1}$ $UGav_{t-1}$ $QPac_{t-1}$ $QPcr_{t-1}$ $QGav_{t-1}$
<i>Modelos Quantitativo-Sazonais</i>	
M01sRNA	Melhor entre M01 e M09 + Estação em (t)
M02sRNA	Melhor entre M01 e M09 + Estação em (t) e $(t+1)$
M03sRNA	Melhor entre M01 e M09 + $P_{mês}$ em (t)
M04sRNA	Melhor entre M01 e M09 + $P_{mês}$ em (t) e $(t+1)$
<i>Modelo Quali-Quantitativo</i>	
M01qRNA	Melhor entre M01 e M09 e entre M01s e M04s + Previsão da Estação seguinte (seca; normal e úmida), baseada no valor da precipitação anual P_{anual}
M02qRNA	Melhor entre M01 e M09 e entre M01s e M04s + Previsão do Mês seguinte (abaixo da média; normal e acima da média), baseada no valor da precipitação mensal

Ainda dentro do processo de identificação dos modelos, deve ser definida a topologia da rede neural (número de camadas, número de unidades em cada camada etc.). Não existe uma regra para a determinação do número de camadas e unidades de processamento, sendo o processo realizado de forma empírica. A utilização de um grande número de camadas ocultas não é recomendada, porque cada vez que o erro médio durante o treinamento é utilizado para

atualizar os pesos das sinapses da camada imediatamente anterior, ele se torna menos útil ou preciso.

Decidiu-se, nesta pesquisa, testar redes neurais com 1 e 2 camadas escondidas. Com relação ao número de neurônios nas camadas escondidas, para comparação entre os diferentes modelos, foram avaliadas configurações com 7, 10 e 13 nós na primeira camada oculta e 6, 9 e 12 na segunda, quando presente. Um número maior de neurônios poderia levar a rede a memorizar os dados de treinamento (*overfitting*), ao invés de extrair as características gerais que permitem a generalização (HAYKIN, 2001). Para o modelo com melhor desempenho, uma análise mais detalhada do número de neurônios em cada camada foi realizada.

A segunda etapa da modelagem, ou seja, o treinamento da rede para cada um dos modelos, considerando as diversas topologias descritas anteriormente, foi realizada de forma supervisionada por meio do algoritmo de retropropagação de erro (*error backpropagation*) descrito no Capítulo 3. Tendo por base o indicador *Erro Percentual Médio Absoluto* (EPMA), a **Tabela 4.19** apresenta, para cada um dos modelos quantitativos testados, as melhores configurações obtidas. Os resultados para todas as configurações testadas estão apresentados no **Anexo III**.

Tabela 4.19 – Indicador de Desempenho – Modelos baseados em Redes Neurais – Modelos Quantitativos

Modelo	Melhor Topologia	Erro Percentual Médio Absoluto (EPMA)							
		Valores Médios		Retirada dos Açudes Pacoti/Riachão		Retirada do Açude Pacajus		Retirada do Canal do Trabalhador	
		CT	CV	CT	CV	CT	CV	CT	CV
M01RNA	3 x 10 x 6 x 3	18,24	21,87	11,18	14,31	23,14	26,15	20,40	25,15
M02RNA	6 x 10 x 9 x 3	15,81	20,67	9,72	13,11	18,97	24,83	18,73	24,08
M03RNA	5 x 10 x 3	17,55	21,20	10,78	11,72	22,61	28,68	19,27	23,21
M04RNA	8 x 7 x 3	28,74	33,46	15,55	16,02	33,32	43,10	37,35	41,28
M05RNA	6 x 13 x 12 x 3	17,20	20,93	10,25	11,70	22,09	26,99	19,25	24,10
M06RNA	9 x 7 x 3	28,70	35,52	15,02	15,79	33,85	45,98	37,24	44,81
M07RNA	12 x 13 x 9 x 3	19,24	32,24	12,97	16,00	14,86	38,53	29,88	42,20
M08RNA	9 x 13 x 12 x 3	13,03	14,88	10,30	11,76	11,99	14,03	16,80	18,86
M09RNA	10 x 7 x 12 x 3	11,85	15,03	8,91	12,35	11,13	13,83	15,52	18,91

CT = Conjunto de Treinamento; CV = Conjunto de Validação

A **Tabela 4.19** apresenta os EPMA tanto para os conjuntos de treinamento da RNA como para os de validação (terceira etapa da modelagem). Para o modelo *M09RNA*, que

apresentou o melhor desempenho entre os modelos quantitativos, os valores de EPMA obtidos para os dois tipos de conjunto são da mesma ordem de grandeza, indicando a boa capacidade de generalização do mesmo.

Conforme **Tabela 4.18**, partindo do modelo *M09RNA*, foram elaborados os modelos quantitativo-sazonais incluindo dois tipos de variáveis para caracterização da estação: (i) *Estação*, caracterizando a estação do ano propriamente dita, com a divisão do ano hidrológico em dois subconjuntos – estação chuvosa para os meses de janeiro a junho e estação seca para os meses de julho a dezembro; e (ii) $P_{Mês}$, caracterizando o mês do ano. Na concepção dos modelos, essas variáveis foram incluídas tanto para o intervalo de tempo t (momento da decisão) como para o intervalo de tempo $t+1$. A **Tabela 4.20** apresenta os EPMA para as topologias de RNAs com melhor desempenho para os modelos quantitativo-sazonais testados. Os resultados para todas as configurações testadas estão apresentados no **Anexo III**.

Tabela 4.20 – Indicador de Desempenho – Modelos baseados em Redes Neurais – Modelos Quantitativo-Sazonais

Modelo	Melhor Topologia	Erro Percentual Médio Absoluto (EPMA)							
		Valores Médios		Retirada dos Açúdes Pacoti/Riachão		Retirada do Açúde Pacajus		Retirada do Canal do Trabalhador	
		CT	CV	CT	CV	CT	CV	CT	CV
M01sRNA	11 x 13 x 3	12,09	14,90	9,55	11,39	11,84	13,94	14,88	19,37
M02sRNA	12 x 10 x 6 x 3	11,67	15,24	9,47	11,65	11,59	14,06	13,95	20,01
M03sRNA	11 x 7 x 12 x 3	11,14	15,24	8,35	11,54	10,96	14,58	14,11	19,60
M04sRNA	12 x 10 x 9 x 3	10,81	15,83	8,22	12,16	11,14	14,35	13,08	20,97

CT = Conjunto de Treinamento; CV = Conjunto de Validação

Pela observação da **Tabela 4.20**, constata-se que a inclusão no modelo quantitativo de uma variável para caracterizar a sazonalidade não resultou em melhorias significativas dos resultados. Esse fato corrobora com a hipótese de grande potencial de aprendizado das RNAs do tipo Perceptron de Múltiplas Camadas, já que indica que estas conseguem identificar em alguns sinais (variáveis) de entrada, tais como as vazões afluentes, as características sazonais, não havendo ganho significativo quando uma variável específica para este fim é incluída no modelo. A inclusão da variável $P_{Mês}$, caracterizando a sazonalidade através do mês do ano no momento da decisão (intervalo de tempo t) – modelo *M03sRNA* –, foi a que proporcionou melhores resultados com a redução do EPMA médio (considerando a média para os conjuntos de treinamento e validação) de 13,44% para 13,19%.

Considerando o modelo *M03sRNA*, foram testados, conforme **Tabela 4.18**, modelos que incluem uma variável de *Previsão Climática*, seja da estação seguinte seja do mês seguinte. A **Tabela 4.21** apresenta os EPMA obtidos.

A inclusão de uma variável de previsão climática caracterizando a precipitação do mês seguinte (modelo *M02qRNA*) como abaixo da média, normal ou acima da média resultou em uma diminuição de 2,73% no EPMA médio. O maior ganho de eficiência ocorreu para a retirada dos açudes Pacoti/Riachão, cujo EPMA médio foi reduzido em 10,42% com a inclusão da previsão climática.

Tabela 4.21 – Indicador de Desempenho – Modelos baseados em Redes Neurais – Modelos Quali-Quantitativos

Modelo	Melhor Topologia	Erro Percentual Médio Absoluto (EPMA)							
		Valores Médios		Retirada dos Açudes Pacoti/Riachão		Retirada do Açude Pacajus		Retirada do Canal do Trabalhador	
		CT	CV	CT	CV	CT	CV	CT	CV
M01qRNA	12 x 7 x 12 x 3	10,61	16,36	8,05	12,78	10,43	15,64	13,35	20,65
M02qRNA	12 x 7 x 6 x 3	11,55	14,60	8,32	10,73	11,89	14,20	14,44	18,87

CT = Conjunto de Treinamento; CV = Conjunto de Validação

Do exposto, conclui-se que o modelo com melhores resultados, e que será utilizado como representativo desse tipo de abordagem para comparação com as demais, é o modelo *M02qRNA*. Destaque-se, no entanto, que, durante o processo de identificação dos modelos, a escolha da função de transferência também pode exercer um papel importante no desempenho do sistema.

Os resultados até agora apresentados decorreram do uso de funções de transferência tipo sigmóide para as camadas ocultas e tipo linear para a camada de saída. Para as funções de transferência linear, foram testadas duas variantes: linear e linear por partes (rampa). Visando verificar a possibilidade de melhoria do desempenho desse modelo, foram testadas outras três alternativas, quais sejam: (i) funções de transferência do tipo sigmóide para todas as camadas; (ii) funções de transferência do tipo linear para as camadas ocultas e do tipo sigmóide para a camada de saída; (iii) funções de transferência do tipo linear para todas as camadas. A **Tabela 4.22** apresenta os valores de EPMA para as diferentes alternativas testadas.

Tabela 4.22 – Análise do uso de diferentes tipos de Funções de Transferência – Modelo baseado em Redes Neurais Artificiais

Tipo das Funções de Transferência		Erro Percentual Médio Absoluto (EPMA)							
Camadas Ocultas	Camada de Saída	Valores Médios		Retirada dos Açudes Pacoti/ Riachão		Retirada do Açude Pacajus		Retirada do Canal do Trabalhador	
		CT	CV	CT	CV	CT	CV	CT	CV
Sigmóide	Linear	11,55	14,60	8,32	10,73	11,89	14,20	14,44	18,87
Sigmóide	Sigmóide	11,72	15,15	8,46	11,22	11,95	14,53	14,76	19,69
Linear	Sigmóide	13,74	15,04	9,66	10,96	13,94	14,32	17,63	19,84
Linear	Linear	13,60	14,83	9,67	10,96	13,61	13,91	17,51	19,61

CT = Conjunto de Treinamento; CV = Conjunto de Validação

A observação dessa tabela deixa evidente a importância da escolha das funções de transferência mais adequadas ao tipo de problema em análise, pois há uma diferença superior a 10% no EPMA médio entre a melhor e a pior alternativa. Para o problema em foco, funções de transferência do tipo sigmóide nas camadas ocultas e do tipo linear na camada de saída são as que proporcionam melhores resultados.

Ainda buscando a topologia da RNA que melhor represente o problema em análise, avaliou-se, para o modelo *M02qRNA*, o comportamento dos EPMA para os conjuntos de treinamento e de validação, bem como seu valor médio, em função do número de nós nas camadas escondidas. Essa análise permitiu também a verificação do comportamento, com o aumento da complexidade da rede, da capacidade de generalização da mesma. A **Figura 4.7** mostra este comportamento considerando inicialmente apenas uma camada oculta.




Figura 4.7 – Variação do EPMA em função do número de nós na primeira camada oculta


Observa-se na **Figura 4.7** que os EPMA's, tanto para o conjunto de treinamento como para o conjunto de validação, diminuem até a rede ter cinco nós (neurônios) na primeira camada oculta. A partir deste ponto, o EPMA para o conjunto de treinamento continua em trajetória decrescente, enquanto para o conjunto de validação, este começa a aumentar, indicando o início do processo de *overfitting* e, conseqüentemente, de perda da capacidade de generalização da rede.

Adotando-se cinco nós como número ótimo de neurônios na primeira camada escondida (menor EPMA de treinamento antes do início do processo de *overfitting*), foram avaliados os comportamentos dos EPMA's para os conjuntos de treinamento e de validação, bem como dos valores médios deste indicador, em função do número de nós em uma segunda camada escondida. Duas situações foram consideradas em relação ao posicionamento dessa camada na rede:


- i) inclusão anterior à camada, com cinco nós (Figura 4.8a);
- ii) inclusão posterior à camada, com cinco nós (Figura 4.8b).

Os resultados obtidos com a inclusão de uma segunda camada são similares nas duas situações testadas, com pequena vantagem para a inclusão da segunda camada oculta posterior à primeira.

Considerando essa situação (**Figura 4.8b**), constata-se que quando a segunda camada possui apenas um neurônio, há um aumento nos EPMA's em relação aos obtidos com a rede com apenas uma camada oculta. Isso indica que a simples inclusão de uma nova camada, e conseqüente aumento de complexidade da rede, não proporciona melhoria no desempenho do modelo. Quando a segunda camada possui dois ou três neurônios, os valores de EPMA são similares aos obtidos com apenas uma camada oculta. Para redes com quatro a seis nós na segunda camada oculta, os EPMA's, tanto para o conjunto de treinamento como para o conjunto de validação, são decrescentes e inferiores aos da rede com uma única camada oculta. A partir deste ponto, no entanto, o EPMA para o conjunto de treinamento continua decrescendo, enquanto para o conjunto de validação, ele começa a aumentar, sinalizando o início do processo de *overfitting* e, conseqüentemente, de perda da capacidade de generalização da rede.



(a) Segunda camada anterior à de 5 nós



(b) Segunda camada posterior à de 5 nós

Figura 4.8 – Variação do EPMA em função do número de nós na segunda camada oculta

Com as investigações complementares realizadas com o modelo *M02qRNA*, ou seja, análises dos tipos de funções de transferência e do número de nós nas camadas ocultas, obteve-se que a melhor arquitetura, e que será utilizada na comparação deste modelo com as demais abordagens, é uma rede com duas camadas ocultas, com cinco nós na primeira e seis nós na segunda, e que utiliza funções de transferência do tipo sigmóide nas camadas ocultas e linear na camada de saída. A **Tabela 4.23** apresenta os indicadores de desempenho do

sistema físico e os graus de eficiência de custos e perdas resultantes, utilizando o modelo *M02qRNA* com esta arquitetura na definição das políticas operacionais.

Tabela 4.23 – Indicadores do Sistema Físico e Graus de Eficiência do Modelo baseado em Redes Neurais Artificiais – Cenários de Comparação

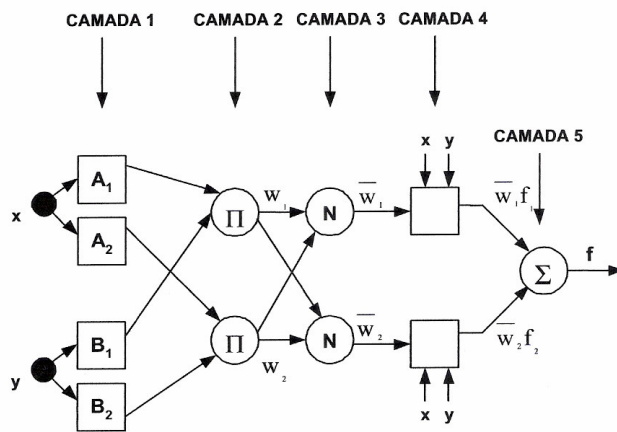
Cenários Hidrológicos Analisados		Indicadores do Sistema Físico					Graus de Eficiência ³	
		Indicador de Custo (Unidade Monetária)	Indicadores de Garantia		Indicador de Perdas (hm ³)			
Tipo	Anos	Custo de Bombeamento	Garantia (%)	Custo de Falha		Custos	Perdas	
Curto Prazo	Seco	1992	1,3145	100,00	0,00	163,55		
	Normal	1987	1,1713	100,00	0,00	161,93		
	Úmido	1964	0,9724	100,00	0,00	2540,00		
	Valores Médios		1,1527	100,00	0,00	955,16		
Médio Prazo	Seco	1957 a 1961	6,6238	100,00	0,00	3258,40	0,804	0,934
	Normal	1972 a 1976	6,0423	100,00	0,00	6211,50	0,809	0,991
	Úmido	1962 a 1966	6,3338	100,00	0,00	5869,20	0,574	0,971
	Valores Médios		6,3333	100,00	0,00	5113,03	0,729	0,965
Longo Prazo	1972 a 1996	33,9047	100,00	0,00	18807,00			

A operação por meio da política operacional oriunda da rede neural artificial mostrou-se mais eficiente que a política operacional heurística (POH) e que a abordagem tradicional que utiliza análise de regressão (POR). Em relação à abordagem tradicional de zoneamento dos reservatórios (POZ), a RNA resultou, em termos médios, custos similares, sendo, no entanto, mais flexível que a POZ. Isso pode ser percebido pela comparação em períodos extremos (secos e úmidos) nos quais os custos obtidos pela RNA foram menores que os obtidos pela POZ, indicando maior adaptabilidade das RNAs a períodos extremos. Em comparação com os Sistemas Especialistas Difusos (SED), as RNAs mostraram-se menos eficientes, tanto em termos de custos como de perdas. Uma análise comparativa mais detalhada com as demais técnicas está apresentada em item específico desta tese.

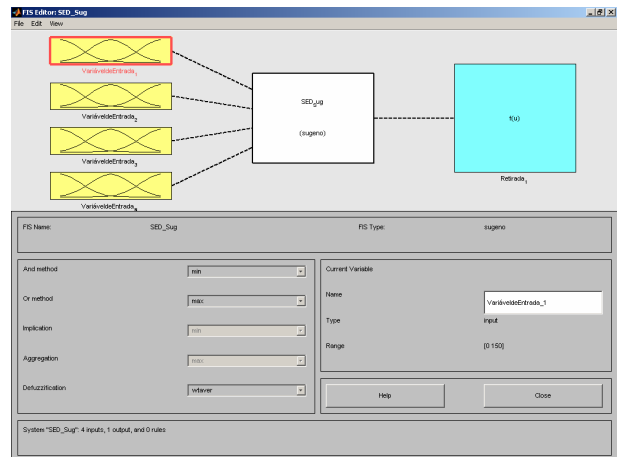
4.5.3 – MODELOS NEURO-DIFUSOS (PDIANFIS)

A modelagem Neuro-Difusa também foi realizada em três etapas: identificação dos modelos, ajuste de regras e validação. Em virtude da dimensão do problema em análise relativamente elevada, a modelagem para as retiradas foi realizada de forma individualizada, ou seja, obteve-se um Sistema de Inferência Adaptativo Neuro-Difuso (ANFIS) para cada uma das retiradas.

A **Figura 4.9** apresenta o esquema geral utilizado. Vale destacar que os sistemas difusos utilizados foram do tipo *Takagi-Sugeno*, diferentemente daqueles utilizados na modelagem baseada exclusivamente em lógica difusa, quando foram usados sistemas especialistas difusos do tipo *Mamdani*.



(a) Arquitetura Geral do Sistema de Inferência Adaptativo Neuro-Difuso (ANFIS)



(b) Configuração Geral do Sistema Especialista Difuso utilizado no ANFIS (SED tipo *Takagi-Sugeno*)

Figura 4.9 – Esquema Geral dos Sistemas de Inferência Adaptativos Neuro-Difusos (ANFIS) utilizados

A **Tabela 4.24** apresenta o processo de identificação dos modelos. Nesta tabela, assim como naquelas que apresentam os modelos baseados em lógica difusa e redes neurais artificiais, há uma divisão em três tipos de modelos, quais sejam: quantitativos, quantitativo-sazonais e quali-quantitativos.

De forma similar à modelagem por lógica difusa, os modelos identificados como *Base (MBaseANFIS e MBase_s_ANFIS)* foram utilizados combinados com os demais modelos, evitando a falta de conhecimento. Ainda no processo de identificação dos modelos, a partição das variáveis foi realizada por meio de análise dos agrupamentos, de forma similar à modelagem por lógica difusa.

A segunda etapa da modelagem, ou seja, a obtenção das regras dos sistemas especialistas difusos para cada um dos modelos, foi realizada por meio do algoritmo ANFIS (*Adaptive Neural Fuzzy Inference System*), conforme descrito no Capítulo 3, implementado através das ferramentas matemáticas do Matlab®.

Tabela 4.24 – Modelos ANFIS

Identificação do Modelo	Antecedentes
<i>Modelos Quantitativos</i>	
MBaseANFIS	VTS_t
M01ANFIS	$VPac_t \quad VPcr_t \quad VGav_t$
M02ANFIS	$VPac_t \quad VPac_{t-1} \quad VPcr_t \quad VPcr_{t-1} \quad VGav_t \quad VGav_{t-1}$
M03ANFIS	$VTS_t \quad VTS_{t-1} \quad QPac_{t-1} \quad QPcr_{t-1}$
M04ANFIS	$VTS_t \quad VTS_{t-1} \quad QPac_{t-1} \quad QPac_{t-2} \quad QPcr_{t-1} \quad QPcr_{t-2}$
M05ANFIS	$VPac_t \quad VPcr_t \quad QPac_{t-1} \quad QPcr_{t-1}$
M06ANFIS	$VPac_t \quad VPcr_t \quad QPac_{t-1} \quad QPac_{t-2} \quad QPcr_{t-1} \quad QPcr_{t-2}$
M07ANFIS	$VTS_t \quad UCnl_{t-1} \quad UPac_{t-1} \quad UPcr_{t-1}$
M08ANFIS	$VTS_t \quad UCnl_{t-1} \quad UPac_{t-1} \quad UPcr_{t-1} \quad QPac_{t-1} \quad QPcr_{t-1}$
M09ANFIS	$VPac_t \quad VPcr_t \quad UCnl_{t-1} \quad UPac_{t-1} \quad UPcr_{t-1}$
M10ANFIS	VTS_t Vazão Afluente Total (VAT) _{t-1} (VAT = QPac + QPcr + QGav)
<i>Modelos Quantitativos Sazonais</i>	
MBase_s_ANFIS	MBaseANFIS + Estação em (t) com 3 categorias (seca, intermediária e chuvosa)
M01sANFIS	Melhor entre M01 e M10 + Estação em (t) com 3 categorias (seca, intermediária e chuvosa)
<i>Modelo Quali-Quantitativo</i>	
M01qANFIS	Melhor entre M01 e M10 e M01s + Previsão da Estação seguinte (seca ; normal e úmida), baseada no valor da precipitação anual P_{anual}
M02qANFIS	Melhor entre M01 e M10 e M01s + Previsão do Mês seguinte (abaixo da média; normal e acima da média), baseada no valor da precipitação mensal

A **Tabela 4.25** apresenta, para os modelos quantitativos, os *Erros Percentuais Médios Absolutos* (EPMA) obtidos com os Sistemas de Inferência Adaptativos Neuro-Difusos resultantes do ajuste.

Os EPMA tanto para os conjuntos de ajuste como para os de validação (terceira etapa da modelagem), são apresentados nesta tabela, percebendo-se, de sua análise, uma equivalência entre os valores obtidos para os dois tipos de conjunto. Isso indica a boa capacidade de generalização dos modelos neuro-difusos testados.

Conforme a **Tabela 4.24**, partindo dos modelos quantitativos com melhores desempenhos, foram elaborados os modelos quantitativo-sazonais, incluindo a variável *Estação* com uma partição em três categorias (seca, intermediária e chuvosa). As demais variáveis mantiveram o mesmo número de partições do modelo correspondente sem sazonalidade. Como as variáveis conseqüentes (retiradas) foram modeladas de forma individualizada, o conjunto de variáveis antecedentes que gera o melhor *Sistema de Inferência Adaptativo Neuro-Difuso* poderia ser diferente para cada uma das variáveis

conseqüentes modeladas. A **Tabela 4.26** apresenta os melhores modelos quantitativos para cada uma das variáveis conseqüentes e os seus respectivos antecedentes. Nesta observa-se que houve coincidência de modelo para as retiradas do açúcar Pacajus e do Canal do Trabalhador.

Tabela 4.25 – Indicador de Desempenho – Modelos Neuro-Difusos – Modelos Quantitativos

Modelo	Erro Percentual Médio Absoluto (EPMA)							
	Valores Médios		Valores Individualizados					
			Pacoti/Riachão		Pacajus		Canal do Trabalhador	
	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação
MBaseANFIS	22,49	22,69	11,14	13,13	31,50	28,68	24,82	26,25
M01ANFIS	20,45	21,86	10,14	14,02	29,31	26,00	21,91	25,57
M02ANFIS	17,99	22,21	9,09	14,31	26,64	25,86	18,23	26,45
M03ANFIS	20,13	21,97	10,62	12,11	28,69	28,98	21,07	24,80
M04ANFIS	19,39	22,10	9,66	12,79	27,48	28,68	21,02	24,84
M05ANFIS	19,28	21,58	10,55	12,62	26,00	28,13	21,30	24,00
M06ANFIS	18,34	22,10	9,60	12,73	24,18	28,86	21,25	24,71
M07ANFIS	13,30	15,74	10,83	12,68	11,97	14,11	17,10	20,43
M08ANFIS	12,52	15,74	10,31	13,01	11,21	13,87	16,05	20,34
M09ANFIS	12,97	16,09	10,38	13,26	12,02	14,56	16,52	20,44
M10ANFIS	21,40	21,79	10,71	12,46	31,37	29,16	22,12	23,77

A **Tabela 4.27** apresenta, para os modelos quantitativo-sazonais, os *Erros Percentuais Médios Absolutos* (EPMAs) obtidos. Observa-se que a inclusão da sazonalidade melhorou os resultados para o SED que representa a retirada dos açúcares Pacoti/Riachão, tanto para o conjunto de ajuste como para o conjunto de validação. No caso do SED para a retirada do Canal do Trabalhador, o modelo quantitativo-sazonal apresentou, em termos médios, desempenho superior, haja vista que o EPMA para o conjunto de ajuste permaneceu praticamente inalterado, enquanto o EPMA para o conjunto de validação foi menor. Já para o SED que representa a retirada do açúcar Pacajus, a situação foi inversa, com o modelo exclusivamente quantitativo apresentando, em termos médios, desempenho superior.

Tabela 4.26 – Modelos Neuro-Difusos – Modelos Quantitativo-Sazonais Adotados

Variável de Saída (Conseqüente)	Melhor Modelo (Quantitativo)					
	Código	Antecedentes				
Retirada dos Açúcares Pacoti/Riachão (uPcr)	M06ANFIS	VPac _t	VPcr _t	QPac _{t-1}	QPac _{t-2}	QPcr _{t-1} QPcr _{t-2}
Retirada do Açúcar Pacajus (uPac)	M08ANFIS	VTS _t	UCnl _{t-1}	UPac _{t-1}	UPcr _{t-1}	QPac _{t-1} QPcr _{t-1}
Retirada do Canal do Trabalhador (uCnl)						

Tabela 4.27 – Indicador de Desempenho – Modelos Neuro-Difusos – Modelos Quantitativo-Sazonais

Modelo	Erro Percentual Médio Absoluto (EPMA)							
	Valores Médios		Valores Individualizados					
			Pacoti/Riachão		Pacajus		Canal do Trabalhador	
	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação
MBase_s_ANFIS	21,04	21,94	10,10	12,13	30,38	28,67	22,63	25,01
M01sANFIS	12,63	15,34	9,47	11,57	11,50	15,02	16,92	19,44

A **Tabela 4.28** apresenta os melhores modelos entre os quantitativos e os quantitativo-sazonais para cada uma das variáveis conseqüentes e os seus respectivos antecedentes. Esses foram utilizados para a incorporação da *Previsão Climática* através de uma variável com partição em três categorias. Para as demais variáveis, foi utilizado o mesmo número de partições do modelo correspondente.

Tabela 4.28 – Modelos Neuro-Difusos – Modelos Quali-Quantitativos Adotados

Variável de Saída (Conseqüente)	Melhor Modelo (Quantitativo ou Quantitativo-Sazonal)							
	Código		Antecedentes					
Retirada dos Açudes Pacoti/Riachão (uPcr)	M01sANFIS	VPac _t	VPcr _t	QPac _{t-1}	QPac _{t-2}	QPcr _{t-1}	QPcr _{t-2}	Estação _t
Retirada do Açude Pacajus (uPac)	M08ANFIS	VTS _t	UCnl _{t-1}	UPac _{t-1}	UPcr _{t-1}	QPac _{t-1}	QPcr _{t-1}	
Retirada do Canal do Trabalhador (uCnl)	M01sANFIS	VTS _t	UCnl _{t-1}	UPac _{t-1}	UPcr _{t-1}	QPac _{t-1}	QPcr _{t-1}	Estação _t

Os valores de EPMA resultantes da inclusão da variável de previsão climática estão apresentados na **Tabela 4.29**. Pela análise desta, constata-se que a inclusão de uma variável de previsão melhorou os resultados em todos os casos. Para as retiradas dos açudes Pacoti/Riachão e do Canal do Trabalhador, a variável de previsão do mês seguinte (modelo *M02qANFIS*) foi a que proporcionou melhores resultados, com a redução do EPMA, respectivamente em 4,1% e 5,2% para os conjuntos de ajuste e em 1,7% e 1,4% para os conjuntos de validação. Já para a retirada do açude Pacajus, a previsão climática da estação seguinte (modelo *M01qANFIS*) foi a que proporcionou melhor desempenho com a redução do EPMA em 1,4% e 1,3%, respectivamente para os conjuntos de ajuste e de validação.

Do exposto, conclui-se que os modelos com melhores resultados, e que serão utilizados como representativos deste tipo de abordagem para comparação com as demais, são: o modelo *M01qANFIS* para a retirada do açude Pacajus e o modelo *M02qANFIS* para as retiradas dos açudes Pacoti/Riachão e do Canal do Trabalhador.

Tabela 4.29 – Indicador de Desempenho – Modelos Neuro-Difusos – Modelos Quali-Quantitativos

Modelo	Erro Percentual Médio Absoluto (EPMA)							
	Valores Médios		Valores Individualizados					
			Pacoti/Riachão		Pacajus		Canal do Trabalhador	
	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação	Ajuste	Validação
M01qANFIS	12,09	15,50	9,49	11,43	11,06	14,05	15,73	21,02
M02qANFIS	12,00	15,65	9,07	11,77	10,91	15,47	16,02	19,72

Com esses modelos e de forma similar à realizada na modelagem por lógica difusa, visando verificar a possibilidade de melhoria do desempenho, foram testadas variações nos tipos de funções de pertinência utilizadas para os conjuntos difusos. Foram testadas as funções do tipo sino e curva de Gauss. A **Tabela 4.30** apresenta os valores de EPMA obtidos.

Tabela 4.30 – Análise do uso de diferentes tipos de Funções de Pertinência – Modelos Neuro-Difusos

Tipo de Função de Pertinência	Erro Percentual Médio Absoluto (EPMA)			
	Valores Médios	SED para a retirada dos Açudes Pacoti/Riachão	SED para a retirada do Açude Pacajus	SED para a retirada do Canal do Trabalhador
Forma de Sino	12,29	9,13	11,87	15,87
Curva de Gauss	12,05	9,07	11,06	16,02

Ficou claro novamente que a escolha de uma função de pertinência adequada ao tipo de problema em análise é de suma importância para obtenção de bons resultados. Para os modelos neuro-difusos desta pesquisa, a função de pertinência do tipo curva de Gauss foi a que proporcionou melhores desempenhos para as retiradas dos açudes Pacoti/Riachão e açude Pacajus, enquanto a do tipo forma de sino resultou em melhor ajuste para a retirada do Canal do Trabalhador.

A **Tabela 4.31** apresenta os indicadores do sistema físico e os graus de eficiência de custos e perdas resultantes da utilização, para obtenção das políticas operacionais, dos modelos neuro-difusos com melhores desempenhos para cada uma das retiradas.

A operação por meio da política operacional oriunda de Sistemas de Inferência Adaptativos Neuro-Difusos mostrou-se menos eficiente que todas as outras abordagens, tanto tradicionais como baseadas em inteligência artificial. Isso indica, para o tipo de problema em análise, a possível inadequação da utilização conjunta do algoritmo ANFIS

com sistemas especialistas do tipo *Takagi-Sugeno*, que utilizam para variável conseqüente (retiradas), no caso desta pesquisa, funções lineares das variáveis antecedentes. Com esta estrutura, obtém-se uma regra para cada protótipo (centro dos agrupamentos), o que se mostrou insuficiente.

Tabela 4.31 – Indicadores do Sistema Físico e Graus de Eficiência do Modelo baseado em Lógica Difusa – Cenários de Comparação

Cenários Hidrológicos Analisados		Indicadores do Sistema Físico					Graus de Eficiência ³	
		Indicador de Custo (Unidade Monetária)	Indicadores de Garantia		Indicador de Perdas (hm ³)			
Tipo	Anos	Custo de Bombeamento	Garantia (%)	Custo de Falha		Custos	Perdas	
Curto Prazo	Seco	1992	3,5077	75,00	1092,80	233,22		
	Normal	1987	1,2980	100,00	0,00	230,99		
	Úmido	1964	0,7845	100,00	0,00	2559,80		
	Valores Médios		1,8634	91,67	364,27	1008,00		
Médio Prazo	Seco	1957 a 1961	18,9587	100,00	0,00	3538,30	0,281	0,934
	Normal	1972 a 1976	23,2852	100,00	0,00	6837,30	0,210	0,991
	Úmido	1962 a 1966	19,6287	100,00	0,00	6309,00	0,185	0,971
	Valores Médios		20,6242	100,00	0,00	5561,53	0,225	0,965
Longo Prazo	1972 a 1996	113,5769	100,00	0,00	21836,00			

4.6 – ANÁLISES COMPARATIVAS

As **Tabelas 4.32** e **4.33** apresentam, respectivamente, resumos dos custos de operação e perdas hídricas para os diversos tipos de abordagens analisados.

Tabela 4.32 – Comparação entre os custos operacionais para as diversas abordagens

Cenários Hidrológicos Analisados		Custos (unidades monetárias)						
		Modelos						
Tipo	Anos	Heurístico (POH)	Análise de Regressão (PDIR)	Zoneamento (PDIZ)	Lógica Difusa (PDID)	Redes Neurais (PDIN)	Neuro-Difuso (PDIANFIS)	
Curto Prazo	Seco	1992	2,25	1,85	1,94	0,96	1,31	3,51
	Normal	1987	2,25	1,72	1,98	1,20	1,17	1,30
	Úmido	1964	2,25	0,98	1,32	0,89	0,97	0,78
	Valores Médios		2,25	1,52	1,75	1,02	1,15	1,86
Médio Prazo	Seco	1957 a 1961	11,59	9,43	6,65	6,20	6,62	18,96
	Normal	1972 a 1976	12,49	7,72	5,87	5,06	6,04	23,29
	Úmido	1962 a 1966	11,70	7,64	7,34	4,16	6,33	19,63
	Valores Médios		11,93	8,26	6,62	5,14	6,33	20,62
Longo Prazo	1972 a 1996	63,38	42,34	42,38	27,13	33,90	113,58	

Tabela 4.33 – Comparação entre as perdas hídricas para as diversas abordagens

Cenários Hidrológicos Analisados		Perdas Hídricas (hm ³)						
		Modelos						
Tipo	Anos	Heurístico (POH)	Análise de Regressão (PDIR)	Zoneamento (PDIZ)	Lógica Difusa (PDID)	Redes Neurais (PDIN)	Neuro- Difuso (PDIANFIS)	
Curto Prazo	Seco	1992	146,10	140,55	135,91	105,91	163,55	233,22
	Normal	1987	144,64	124,12	120,19	121,72	161,93	230,99
	Úmido	1964	2576,40	2534,10	2548,00	2539,10	2540,00	2559,80
	Valores Médios		955,71	932,92	934,70	922,24	955,16	1008,00
Médio Prazo	Seco	1957 a 1961	3409,80	3268,30	3077,00	3180,60	3258,40	3538,30
	Normal	1972 a 1976	6429,30	6223,90	6071,50	6131,60	6211,50	6837,30
	Úmido	1962 a 1966	5998,40	5877,80	5815,80	5783,80	5869,20	6309,00
	Valores Médios		5279,17	5123,33	4988,10	5032,00	5113,03	5561,53
Longo Prazo	1972 a 1996	19765,0	18899,0	18507,0	18267,0	18807,0	21836,0	

Com relação aos custos, percebe-se, para todas as situações hidrológicas analisadas, a superioridade dos Sistemas Especialistas Difusos (modelo PDID). As redes neurais artificiais (modelo PDIN) também se mostraram mais eficientes que as abordagens tradicionais. Essas duas constatações confirmam a hipótese desta tese, ou seja, que as mesmas são caminhos efetivos e eficientes para modelar sistemas complexos de múltiplos reservatórios. Entre as abordagens tradicionais, merece destaque a abordagem baseada em zoneamento dos reservatórios (modelo PDIZ), cujo desempenho é similar àquele obtido pelas RNA. Merece destaque, também, o desempenho negativo dos sistemas neuro-difusos (modelo PDIANFIS), que não se mostraram adequados ao tipo de problema em análise, possivelmente em virtude da utilização conjunta do algoritmo ANFIS com o sistema difuso do tipo *Takagi-Sugeno* com funções lineares.

Quanto às perdas hídricas, as diversas abordagens, tanto tradicionais como baseadas em inteligência artificial, mostraram desempenhos similares, com destaque para o zoneamento dos reservatórios (modelo PDIZ) entre as abordagens tradicionais e para os sistemas especialistas difusos (modelo PDID) entre as abordagens baseadas em inteligência artificial. Essas duas abordagens apresentaram para o período de longo prazo, perdas hídricas respectivamente de 6,4% e 7,6% inferiores àquelas decorrentes da política operacional heurística (POH), muito utilizada na região. Isso representa, em relação à POH, uma economia de água superior a 50 hm³ por ano, valor suficiente para o atendimento de mais de três meses da demanda do sistema em análise, resultado obtido mesmo tendo como função-objetivo a minimização dos custos e não das perdas hídricas. O destaque negativo foram

novamente os sistemas neuro-difusos, que resultaram nas maiores perdas hídricas entre todos os modelos.

A **Figura 4.10** apresenta as trajetórias do volume total do sistema (VTS) para o cenário de longo prazo, obtidas pelos diversos tipos de abordagens. Pela análise dessa figura, constata-se que, nos períodos secos, as metodologias baseadas em lógica difusa e redes neurais artificiais resultam em menores volumes acumulados, sem comprometer a garantia de abastecimento e sem aumentar os custos operacionais para atendimento da demanda, reduzindo, por consequência, as perdas hídricas (evaporação e vertimento). Nos períodos normais e úmidos, as trajetórias praticamente coincidem.

Também para o cenário de longo prazo, as **Figuras 4.11 a 4.13** apresentam, respectivamente, as trajetórias das retiradas dos açudes Pacoti/Riachão, do açude Pacajus e do Canal do Trabalhador para os modelos com melhores resultados. Percebe-se que para as retiradas do açude Pacajus e do Canal do Trabalhador, as metodologias baseadas em lógica difusa e redes neurais artificiais propiciam maior amplitude nos valores, facilitando a adaptabilidade a diferentes situações hidrológicas. Entre elas, aquelas baseadas em lógica difusa resultam em maiores variações, sendo esse fato uma das causas dos melhores resultados (custos e perdas hídricas menores) resultantes desse tipo de abordagem.

Nas retiradas dos açudes Pacoti/Riachão, esse comportamento não se repete, possivelmente porque, pelas características do sistema em análise, essa transferência só acarreta custos operacionais quando os níveis dos reservatórios estão muito baixos, tendo menor impacto na função de custo utilizada na otimização.

Fazendo uso de cenários de curto prazo, são apresentadas a seguir comparações em pares entre abordagens tradicionais e baseadas em inteligência artificial, bem como entre as técnicas de inteligência artificial entre si, analisando o comportamento das políticas operacionais em diferentes situações hidrológicas quando submetidas a diferentes condições iniciais. Esta análise, combinando as características do período (seco, normal ou úmido) com diversas condições iniciais, permitiu a avaliação das políticas operacionais em situações hidrológicas bastante diversas, possibilitando a verificação da confiabilidade das mesmas.

As comparações apresentadas são: (i) modelo baseado em análise de regressão (PDIR) \times modelo baseado em redes neurais artificiais (PDIN); (ii) modelo baseado em zoneamento dos reservatórios (PDIZ) \times modelo baseado em lógica difusa (PDID); (iii) modelo baseado em redes neurais artificiais (PDIN) \times modelo baseado em lógica difusa (PDID).

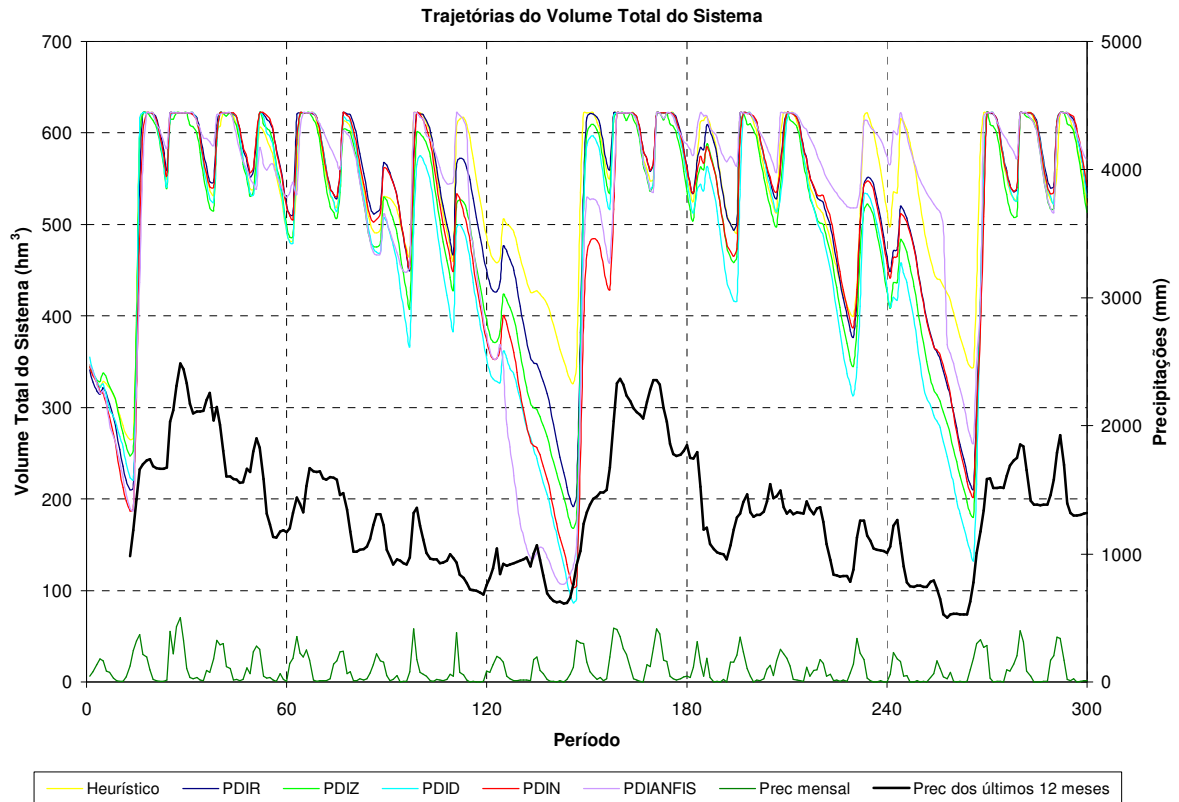


Figura 4.10 – Trajetórias do Volume Total do Sistema (VTS) obtidas pelos diversos tipos de abordagem – Cenário de Longo Prazo




Figura 4.11 – Trajetórias das Retiradas dos Açúes Pacoti/Riachão obtidas pelos diversos tipos de abordagem – Cenário de Longo Prazo




Figura 4.12 – Trajetórias das Retiradas do Açude Pacajus obtidas pelos diversos tipos de abordagem – Cenário de Longo Prazo




Figura 4.13 – Trajetórias das Retiradas do Canal do Trabalhador obtidas pelos diversos tipos de abordagem – Cenário de Longo Prazo

PDIR x PDIN

As **Figuras 4.14 a 4.16** apresentam a comparação dos custos operacionais e perdas hídricas obtidos com o modelo tradicional PDIR (uso conjunto de PDI e análise de regressão) e com o modelo baseado em inteligência artificial PDIN (uso conjunto de PDI e redes neurais artificiais), respectivamente para períodos dos tipos seco, normal e úmido.




Figura 4.14 – PDIR x PDIN – Comparação de Custos e Perdas Hídricas – Cenário de Curto Prazo do tipo seco.




Figura 4.15 – PDIR x PDIN – Comparação de Custos e Perdas Hídricas – Cenário de Curto Prazo do tipo normal.




Figura 4.16 – PDIR x PDIN – Comparação de Custos e Perdas Hídricas – Cenário de Curto Prazo do tipo úmido

Observa-se nessas figuras que, para períodos secos, o modelo PDIN resulta em custos menores, quaisquer que sejam as condições iniciais. Para períodos normais ocorridos quando o sistema esteja com nível baixo de acumulação, o modelo PDIN também resulta em menores custos. Já para períodos normais ocorridos quando o sistema esteja com bom nível de acumulação (maior que 70%), ou para períodos úmidos, independentemente das condições iniciais, os custos resultantes das duas metodologias são similares. Há, portanto, certa superioridade do modelo PDIN sobre o modelo PDIR, que tem como uma de suas justificativas o fato de o PDIN se adaptar melhor a diferentes situações hidrológicas.

Quanto às perdas hídricas, o modelo PDIR resulta, em média, em perdas 15% e 25% menores, respectivamente nos períodos secos e normais. Nos períodos úmidos, as perdas são equivalentes.

PDIZ x PDID

As **Figuras 4.17 a 4.19** apresentam a comparação dos custos operacionais e das perdas hídricas obtidos com o modelo tradicional PDIZ (uso conjunto de PDI e zoneamento dos reservatórios) e com o modelo baseado em inteligência artificial PDID (uso conjunto de PDI e lógica difusa), respectivamente para períodos dos tipos seco, normal e úmido.




Figura 4.17 – PDIZ x PDID – Comparação de Custos e Perdas Hídricas – Cenário de Curto Prazo do tipo seco.




Figura 4.18 – PDIZ x PDID – Comparação de Custos e Perdas Hídricas – Cenário de Curto Prazo do tipo normal.




Figura 4.19 – PDIZ x PDID – Comparação de Custos e Perdas Hídricas – Cenário de Curto Prazo do tipo úmido

Nessas figuras, observa-se a superioridade do modelo baseado em lógica difusa (PDID) em todos os cenários analisados e para quaisquer condições iniciais. Os custos obtidos pelo PDID, mantidos os mesmos níveis de garantia e de abastecimento, são, em média, 38%, 34% e 42% menores, respectivamente para os cenários seco, normal e úmido. As diferenças de custos são maiores para situações de escassez hídrica – período seco ou condição inicial com baixos níveis de acumulação. A maior flexibilidade e a maior adaptabilidade ao problema em análise e à situação do sistema no momento da decisão dos sistemas especialistas difusos perante o zoneamento dos reservatórios estão entre as causas dessa superioridade.

Quanto às perdas hídricas, os modelos PDIZ e PDID apresentam resultados similares, com vantagem para o modelo PDID em períodos secos e para o modelo PDIZ em períodos normais. A vantagem, em termos de perdas hídricas, do PDID em períodos secos torna esse modelo ainda mais atraente, pois, para uma região de escassez hídrica e com altas perdas potenciais por evaporação, como a estudada nesta pesquisa, uma metodologia que seja capaz de aliar custos operacionais baixos com perdas hídricas menores em períodos críticos, mantidos os níveis de garantia e de abastecimento, é a mais indicada.

PDIN x PDID

As Figuras 4.20 a 4.22 apresentam, respectivamente para períodos dos tipos seco, normal e úmido, a comparação dos custos operacionais e perdas hídricas obtidos pelos modelos PDIN e PDID, ambos baseados em inteligência artificial.




Figura 4.20 – PDIN x PDID – Comparação de Custos e Perdas Hídricas – Cenário de Curto Prazo do tipo seco.




Figura 4.21 – PDIN x PDID – Comparação de Custos e Perdas Hídricas – Cenário de Curto Prazo do tipo normal.




Figura 4.22 – PDIN x PDID – Comparação de Custos e Perdas Hídricas – Cenário de Curto Prazo do tipo úmido

Nestas figuras, observa-se que o modelo baseado em redes neurais (PDIN) resultou em menores custos nas situações de maior escassez hídrica – período seco ou condição inicial com baixos níveis de acumulação –, enquanto o modelo baseado em lógica difusa (PDID) foi mais eficiente, do ponto de vista dos custos, em períodos normais ou úmidos. Quanto às perdas hídricas, os resultados foram similares para o período úmido, enquanto nos períodos secos e normais, o modelo PDID apresentou menores valores de perdas.

Considerando que os dois modelos apresentam desempenhos satisfatórios, fato comprovado pelas comparações, apresentadas anteriormente, destes com as abordagens tradicionais, e que ambos são flexíveis e adaptáveis tanto à situação hidrológica como à do sistema no momento da decisão, além de permitirem o aperfeiçoamento constante (inclusão de novos conhecimentos) e a inclusão, por meio de variáveis semânticas, da experiência dos técnicos, a escolha entre os dois será influenciada, em grande parte, pelas preferências do decisor. Caso este queira menores perdas hídricas, a escolha recairá sobre o modelo PDID. Caso queira menores custos em períodos secos, aceitando maiores perdas hídricas, a escolha recairá sobre o modelo PDIN. A adoção de uma solução conjunta também pode ser interessante.

4.7 – ANÁLISE DA INCLUSÃO DE VARIÁVEIS QUALITATIVAS (SEMÂNTICAS)

Para avaliar o impacto nos custos operacionais e nas perdas hídricas da inclusão de variáveis qualitativas (semânticas) de previsão climática, foram comparados os melhores modelos baseados em inteligência artificial COM e SEM a inclusão da variável de previsão (**Tabela 4.34**). As características dos sistemas especialistas difusos e as topologias das redes neurais artificiais foram as mesmas nos dois casos. As variações nos resultados, portanto, foram decorrentes exclusivamente da inclusão da variável de previsão.

Tabela 4.34 – Modelos comparados na Análise de Inclusão da Variável de Previsão Climática

Tipo de Abordagem	Variável de Saída	Melhores Modelos	
		SEM previsão climática	COM previsão climática
Lógica Difusa	Retirada dos Açudes Pacoti/Riachão	M01sSED	M02qSED
	Retirada do Açude Pacajus	M09SED	M02qSED
	Retirada do Canal do Trabalhador	M01sSED	M02qSED
Redes Neurais Artificiais	Retirada dos Açudes Pacoti/Riachão		
	Retirada do Açude Pacajus	M03sRNA	M02qRNA
	Retirada do Canal do Trabalhador		

A **Tabela 4.35** apresenta os valores de custos operacionais e perdas hídricas obtidos com os modelos baseados em lógica difusa (PDID) COM e SEM a inclusão da variável de previsão climática, enquanto a **Tabela 4.36** apresenta os mesmos tipos de resultados obtidos com os modelos baseados em redes neurais artificiais (PDIN).

Pela análise da **Tabela 4.35**, constata-se que, para os modelos baseados em lógica difusa (PDID), a inclusão de uma variável de previsão climática melhorou os resultados em todos os cenários analisados. Os custos operacionais foram reduzidos de forma significativa, em média 25,90%, 16,97% e 24,30%, respectivamente para os cenários de curto, médio e longo prazo. As perdas hídricas também foram reduzidas, em média 16,54%, 5,66% e 3,35% respectivamente para os mesmos tipos de cenários.

Para os modelos baseados em redes neurais artificiais (PDIN), observa-se na **Tabela 4.36** que aqueles COM previsão climática foram superiores em todos os cenários de médio e longo prazo, reduzindo tanto os custos operacionais como as perdas hídricas. Os custos foram reduzidos, em média, 14,06% para os cenários de médio prazo e 20,74% para o cenário de longo prazo. As perdas hídricas foram reduzidas, em média, 4,92% para os cenários de médio prazo e 1,40% para o cenário de longo prazo.

Tabela 4.35 – Análise da Inclusão de variável semântica – Modelos baseados em Lógica Difusa (PDID)

Indicador	Cenários Hidrológicos Analisados		Modelos		Variação (%)	
			SEM previsão climática	COM previsão climática		
	Tipo	Anos				
Custos Operacionais	Curto Prazo	Seco	1992	1,4678	0,9570	-34,80%
		Normal	1987	1,5120	1,2039	-20,38%
		Úmido	1964	1,1399	0,8919	-21,76%
		Valores Médios		1,3732	1,0176	-25,90%
	Médio Prazo	Seco	1957 a 1961	6,5281	6,1955	-5,09%
		Normal	1972 a 1976	6,3884	5,0571	-20,84%
		Úmido	1962 a 1966	5,6509	4,1637	-26,32%
		Valores Médios		6,1891	5,1388	-16,97%
		Longo Prazo	1972 a 1996	35,8354	27,1270	-24,30%
	Perdas Hídricas	Curto Prazo	Seco	1992	252,64	105,91
Normal			1987	249,91	121,72	-51,30%
Úmido			1964	2812,40	2539,10	-9,72%
		Valores Médios		1104,99	922,24	-16,54%
Médio Prazo		Seco	1957 a 1961	3443,00	3180,60	-7,62%
		Normal	1972 a 1976	6450,90	6131,60	-4,95%
		Úmido	1962 a 1966	6107,40	5783,80	-5,30%
		Valores Médios		5333,77	5032,00	-5,66%
		Longo Prazo	1972 a 1996	18901,00	18267,00	-3,35%

Tabela 4.36 – Análise da Inclusão de variável semântica - Modelos baseados em Redes Neurais Artificiais (PDIN)

Indicador	Cenários Hidrológicos Analisados		Modelos		Variação (%)	
			SEM previsão climática	COM previsão climática		
	Tipo	Anos				
Custos Operacionais	Curto Prazo	Seco	1992	1,0640	1,3145	23,54%
		Normal	1987	1,0522	1,1713	11,32%
		Úmido	1964	0,9031	0,9724	7,67%
		Valores Médios		1,0064	1,1527	14,54%
	Médio Prazo	Seco	1957 a 1961	7,2582	6,6238	-8,74%
		Normal	1972 a 1976	7,2420	6,0423	-16,57%
		Úmido	1962 a 1966	7,6089	6,3338	-16,76%
		Valores Médios		7,3697	6,3333	-14,06%
		Longo Prazo	1972 a 1996	42,7744	33,9047	-20,74%
	Perdas Hídricas	Curto Prazo	Seco	1992	254,00	163,55
Normal			1987	243,41	161,93	-33,48%
Úmido			1964	2803,00	2540,00	-9,38%
		Valores Médios		1100,13	955,16	-13,18%
Médio Prazo		Seco	1957 a 1961	3501,70	3258,40	-6,95%
		Normal	1972 a 1976	6512,70	6211,50	-4,62%
		Úmido	1962 a 1966	6118,50	5869,20	-4,07%
		Valores Médios		5377,63	5113,03	-4,92%
		Longo Prazo	1972 a 1996	19074,00	18807,00	-1,40%

Destaque-se que o modelo PDIN SEM previsão resultou em custos menores que o modelo PDIN COM previsão nos cenários de curto prazo, mas com perdas hídricas mais elevadas. Isso decorre do fato de a previsão climática ter pouca influência no curto prazo. As perdas hídricas de curto prazo, no entanto, geram, em cenários de médio e longo prazo, maiores necessidades de bombeamento e, portanto, maiores custos operacionais, fato confirmado pelo melhor desempenho dos modelos com previsão para esses tipos de cenários.

Haja vista que os modelos que incluíram a previsão climática mostraram-se superiores aos demais, tornou-se importante avaliar as conseqüências decorrentes de erros nas previsões. As **Tabelas 4.37 e 4.38** apresentam, respectivamente para os modelos PDID e PDIN, a comparação dos valores dos indicadores de custos operacionais e perdas hídricas para o modelo SEM previsão e para o modelo COM previsão em três situações:

- (i) acerto das previsões em todos os períodos;
- (ii) erros nas previsões, considerando como períodos normais aqueles que se concretizaram como secos;
- (iii) erros nas previsões, considerando períodos úmidos aqueles que se concretizaram como normais e normais aqueles que se concretizaram como secos.

Vale destacar que, nas situações (ii) e (iii) dos modelos COM previsão, o erro foi sempre para uma situação de maior escassez hídrica do que a prevista. Nas **Tabelas 4.37 e 4.38** são apresentadas somente comparações para os cenários de médio e longo prazo, haja vista a pouca influência da variável de previsão nos cenários de curto prazo, conforme constatado anteriormente.

A análise destas tabelas revela que as situações com erros nas previsões provocaram aumentos nos custos operacionais (até 39,97% nos cenários de médio prazo e até 6,77% no cenário de longo prazo) e nas perdas hídricas (até 8,86% nos cenários de médio prazo e cerca de 2% no cenário de longo prazo), indicando a necessidade de uma boa previsão.

Vale destacar, no entanto, que os valores dos custos operacionais e das perdas hídricas obtidos com os modelos COM previsões, nos casos com erros nestas previsões, foram da mesma ordem de grandeza ou até mesmo inferiores àqueles obtidos pelos modelos SEM previsão. Esse fato justifica a adoção, com segurança, de modelos COM previsões climáticas, mesmo submetidos a erros eventuais, certamente inferiores, na operação real, aos impostos nas situações analisadas anteriormente.

Tabela 4.37 – Análise do impacto de erros nas previsões climáticas – Modelos baseados em Lógica Difusa (PDID)

Indicador	Cenários Hidrológicos Analisados	Modelos SEM Previsão climática	Valor do Indicador com acerto na previsão	Modelos COM previsão climática				
				Previsão equivocada: considerando períodos normais aqueles que se concretizaram como secos		Previsão equivocada: considerando períodos úmidos aqueles que se concretizaram como normais e normais aqueles que se concretizaram como secos		
				Tipo	Valor do Indicador	Valor do Indicador	Variação (%)	Valor do Indicador
Custos Operacionais	Médio Prazo	Seco	6,5281	6,1955	6,3017	1,71%	6,9824	12,70%
		Normal	6,3884	5,0571	5,1407	1,65%	4,6973	-7,11%
		Úmido	5,6509	4,1637	5,8278	39,97%	5,5421	33,11%
		Média	6,1891	5,1388	5,7567	12,03%	5,7406	11,71%
	Longo Prazo		35,8354	27,1270	28,9647	6,77%	27,3622	0,87%
Perdas Hídricas	Médio Prazo	Seco	3443,00	3180,60	3413,60	7,33%	3432,40	7,92%
		Normal	6450,90	6131,60	6447,20	5,15%	6430,50	4,87%
		Úmido	6107,40	5783,80	6108,10	5,61%	6109,10	5,62%
		Média	5333,77	5032,00	5322,97	5,78%	5324,00	5,80%
	Longo Prazo		18901,00	18267,00	18666,00	2,18%	18668,00	2,20%

Tabela 4.38 – Análise do impacto de erros nas previsões climáticas – Modelos baseados em redes neurais artificiais (PDIN)

Indicador	Cenários Hidrológicos Analisados	Modelos SEM Previsão climática	Valor do Indicador com acerto na previsão	Modelos COM previsão climática				
				Previsão equivocada: considerando períodos normais aqueles que se concretizaram como secos		Previsão equivocada: considerando períodos úmidos aqueles que se concretizaram como normais e normais aqueles que se concretizaram como secos		
				Tipo	Valor do Indicador	Valor do Indicador	Variação (%)	Valor do Indicador
Custos Operacionais	Médio Prazo	Seco	7,2582	6,6238	6,7485	1,88%	6,7114	1,32%
		Normal	7,2420	6,0423	6,3469	5,04%	6,1552	1,87%
		Úmido	7,6089	6,3338	6,5023	2,66%	6,4453	1,76%
		Média	7,3697	6,3333	6,5326	3,15%	6,4373	1,64%
	Longo Prazo		42,7744	33,9047	34,8896	2,90%	34,3246	1,24%
Perdas Hídricas	Médio Prazo	Seco	3501,70	3258,40	3547,20	8,86%	3534,10	8,46%
		Normal	6512,70	6211,50	6532,40	5,17%	6522,00	5,00%
		Úmido	6118,50	5869,20	6156,40	4,89%	6148,60	4,76%
		Média	5377,63	5113,03	5412,00	5,85%	5401,57	5,64%
	Longo Prazo		19074,00	18807,00	19168,00	1,92%	19114,00	1,63%

4.8 – ANÁLISE DO USO DE MODELOS HIERARQUICAMENTE ESCALONADOS

Um dos problemas mais frequentes em Sistemas Especialistas Difusos é o que se denomina *Falta de Conhecimento*. Para superar essa dificuldade, foram utilizados nesta pesquisa *Modelos Hierarquicamente Escalonados (MHE)*. Apresenta-se, a seguir, através de análises comparativas no cenário de longo prazo, uma análise sobre a importância do uso deste artifício. A **Tabela 4.39** apresenta a comparação dos indicadores de custos operacionais e perdas hídricas com e sem a utilização dos *MHE*. Apresenta, também, o número de eventos, durante os 25 anos de simulação, onde a falta de conhecimento foi registrada.

Tabela 4.39 – Análise do uso de Modelos Hierarquicamente Escalonados

Indicador	PDID COM uso de Modelos Hierarquicamente Escalonados	PDID SEM uso de Modelos Hierarquicamente Escalonados			Valor do Indicador	Variação (%)
		Número de Eventos com Falta de Conhecimento				
		SED para a retirada dos Açudes Pacoti/ Riachão	SED para a retirada do Açude Pacajus	SED para a retirada do Canal do Trabalhador		
Custos Operacionais	27,1270	31	282	242	65,1298	140,1%
Perdas Hídricas	18267,00				20259,00	10,9%

Pela observação dessa tabela, constata-se a importância do uso dos *MHE*. A não utilização desse artifício provoca *falta de conhecimento* em 10%, 94% e 80% do tempo, respectivamente para as retiradas dos açudes Pacoti/Riachão, do açude Pacajus e do Canal do Trabalhador, com aumento de 140,1% nos custos operacionais e de 10,9% nas perdas hídricas para o cenário de longo prazo.

CAPÍTULO 5 – CONCLUSÕES E RECOMENDAÇÕES

5 – CONCLUSÕES E RECOMENDAÇÕES

5.1 – CONCLUSÕES E CONTRIBUIÇÕES AO ESTADO DA ARTE

A hipótese investigada nesta pesquisa foi a de que metodologias baseadas em técnicas de inteligência artificial são caminhos efetivos e eficientes para a obtenção de políticas operacionais de sistemas complexos de reservatórios. As definições e as implementações dos esquemas metodológicos propostos e suas aplicações no estudo de caso do sistema que abastece a Região Metropolitana de Fortaleza (RMF) confirmaram essa hipótese para duas das três técnicas avaliadas – os modelos baseados em lógica difusa (PDID) e os modelos baseados em redes neurais artificiais (PDIN). A terceira técnica testada – sistemas de inferência adaptativos neuro-difusos (PDIANFIS) – apresentou resultados insatisfatórios.

O sistema escolhido para o estudo de caso se mostrou adequado, permitindo a análise dos diversos tipos de abordagem em situações hidrológicas bastante diversas e representativas de regiões semi-áridas em um sistema com histórico recente de risco de racionamento e colapso de abastecimento.

O primeiro passo dos esquemas metodológicos propostos foi a geração de uma *Biblioteca de Conhecimentos* (BC) ou Base de Dados. Para isso, foi utilizado um algoritmo de programação dinâmica incremental (PDI). A escolha dessa técnica foi motivada pelas características do problema em análise – um sistema dinâmico com decisões em estágios sequenciais de tempo. Os resultados comprovaram a eficiência da PDI para o fim proposto.

Para efeito de comparação e verificação das potencialidades das técnicas baseadas em inteligência artificial, foram utilizados três tipos de políticas operacionais já consolidados na literatura. A primeira – denominada Heurística (POH) – é baseada no conhecimento dos técnicos da região. As outras duas – em conjunto denominadas abordagens tradicionais – foram baseadas em análise de regressão (POR) e no zoneamento dos reservatórios do sistema (POZ), ambas tendo como ponto de partida para suas definições os valores ótimos obtidos pela PDI presentes na Biblioteca de Conhecimentos.

Vale destacar o bom desempenho obtido com as abordagens tradicionais, já comprovado na literatura (YEH, 1985 e LIMA e LANNA, 2005), que, ao serem comparadas com a política operacional heurística (POH), resultaram, quando utilizados cenários de

médio prazo (cinco anos), em custos 30% (POR) e 44% (POZ) menores e em perdas hídricas 3% (POR) e 5% (POZ) menores.

Os modelos baseados em inteligência artificial foram implementados em três etapas: identificação dos modelos, treinamento ou ajuste das regras e validação. A validação é etapa essencial da modelagem e, para isto, foram utilizadas informações presentes na Biblioteca de Conhecimentos não utilizadas no treinamento ou ajuste de regras.

Os modelos baseados em lógica difusa (PDID) utilizaram um sistema especialista difuso do tipo *Mamdani* para cada uma das variáveis de saída (conseqüentes). Como antecedentes (variáveis de entrada), foram utilizadas combinações das seguintes variáveis em diferentes momentos no tempo: volume total do sistema, volume de cada um dos reservatórios do sistema, vazão afluyente total, vazões afluentes a cada um dos reservatórios do sistema e retiradas (vazões efluentes). Foram consideradas também variáveis que caracterizam a sazonalidade – formando os modelos denominados quantitativo-sazonais – e variáveis qualitativas (semânticas) de previsão climática – formando os modelos denominados quali-quantitativos.

Como artifício para combater a falta de conhecimento, problema muito comum no uso de sistemas especialistas difusos (PEDROLLO, 2000), foram utilizados modelos com um número reduzido de antecedentes, denominados *Modelos Base*, para, de forma combinada com modelos mais complexos – *Modelos Hierarquicamente Escalonados (MHE)* –, proporcionar melhores resultados. Essa estratégia se mostrou adequada melhorando de forma significativa os resultados tanto em termos de custos operacionais como de perdas hídricas.

O ajuste das regras dos modelos PDID foi realizado tanto de forma heurística como por meio de algoritmo de treinamento organizativo desenvolvido por PEDROLLO e LANNA (2000). Nos dois casos, análises de agrupamentos dos conjuntos difusos foram utilizadas para auxiliar no processo de partição dos universos de domínio. Essa estrutura metodológica se mostrou adequada. A análise de agrupamentos aliada ao treinamento organizativo gerou os melhores resultados.

Para a configuração final dos sistemas especialistas difusos, foram testadas funções de pertinência dos tipos triangular, trapezoidal, curva de Gauss e forma de sino. Os melhores resultados foram obtidos com a do tipo trapezoidal.

Os modelos baseados em redes neurais artificiais (PDIN) e os sistemas híbridos neuro-difusos (PDIANFIS) utilizaram, no processo de identificação, variáveis de entrada similares às das dos modelos baseados em lógica difusa (PDID), considerando também modelos quantitativo-sazonais e quali-quantitativos.

Nos modelos PDIN, a melhor arquitetura foi identificada analisando redes com uma e duas camadas ocultas, sempre com três nós na camada de saída, representando as retiradas dos açudes Pacoti/Riachão, do açude Pacajus e do Canal do Trabalhador. Após testes iniciais com 7, 10 e 13 nós na primeira camada oculta e 6, 9 e 12 nós na segunda camada oculta, foi implementada uma estratégia de investigação do número ótimo de nós nas camadas ocultas. Essa estratégia mostrou-se adequada, podendo-se, com ela, identificar a configuração a partir da qual começa o processo de supertreinamento (*overfitting*) da rede, com a perda da capacidade de generalização da mesma. O treinamento da rede foi realizado de forma supervisionada por meio de algoritmo de retro-propagação dos erros (*backpropagation algorithm*).

Nos modelos híbridos neuro-difusos (PDIANFIS), sistemas especialistas difusos do tipo Takagi-Sugeno foram adotados. O ajuste das regras foi realizado aliando análises de agrupamentos difusos e o algoritmo definido por JANG (1993), denominado ANFIS (*Adaptive-network-based fuzzy inference system*). Os resultados indicaram a inadequação dessa estrutura para o problema em análise, gerando custos operacionais e perdas hídricas superiores aos obtidos com todas as demais abordagens, inclusive aqueles obtidos com a política operacional heurística.

Em termos quantitativos, os modelos baseados em lógica difusa (PDID) apresentaram custos operacionais 32,95%, 22,32% e 35,98% menores, respectivamente para os cenários de curto, médio e longo prazo, quando comparados com a abordagem tradicional com melhores resultados (zoneamento – modelos PDIZ). Os modelos baseados em redes neurais (PDIN) apresentaram, para os mesmos tipos de cenários, custos operacionais 24,04%, 4,06% e 19,99% menores quando comparados aos obtidos pelos modelos PDIZ. Quanto às perdas hídricas, todas as abordagens mostraram desempenhos similares.

A inclusão de variável de previsão climática nos modelos PDID e PDIN – formando os chamados modelos quali-quantitativos – provocou melhorias significativas nos resultados. Para os cenários de médio prazo, os custos foram reduzidos, em média, 16,97% nos modelos PDID e 14,04% nos modelos PDIN. As perdas hídricas, também para os cenários de médio prazo, foram, em média, 5,66% (PDID) e 4,92% (PDIN) menores. Para o cenário de longo

prazo, os custos foram 24,30% (PDID) e 20,74% (PDIN) menores, enquanto as perdas hídricas foram reduzidas em 3,35% (PDID) e 1,40% (PDIN). Mesmo com a ocorrência de eventuais erros de previsão, os modelos COM previsão se mostraram satisfatórios gerando menores custos operacionais e perdas hídricas que seus correspondentes SEM previsão. Os modelos quali-quantitativos baseados em lógica difusa e redes neurais artificiais foram os que apresentaram os melhores resultados entre todas as abordagens e modelos testados.

A grande desvantagem do uso de modelos baseados em inteligência artificial é o esforço necessário – tanto em processos por tentativa e erro como nos tempos computacionais de outros algoritmos automatizados – para treinamento e ajuste de regras. No caso da presente pesquisa, alguns processos de ajuste de regras duraram cerca de 30 horas em computador com processador Pentium 4®.

As contribuições desta pesquisa ao estado da arte estão principalmente nos seguintes pontos:

- ✓ definição de esquemas metodológicos utilizando abordagens baseadas em sistemas inteligentes – Lógica Difusa, Redes Neurais Artificiais e Sistemas Neuro-Difusos – na obtenção de políticas operacionais para sistemas de reservatórios em regiões semi-áridas;
- ✓ inclusão, nos sistemas inteligentes para obtenção de políticas operacionais, de variáveis semânticas (qualitativas) indicativas da previsão climática, avaliando tanto a melhora do processo de operação dos reservatórios quanto os erros potenciais decorrentes de previsões equivocadas;
- ✓ utilização, em conjunto, de técnicas de agrupamento (*clustering*) e de aprendizado organizativo na construção de sistemas especialistas difusos para operação de sistemas de reservatórios;
- ✓ construção e utilização, para os sistemas especialistas difusos de operação de reservatórios, de *Modelos Hierarquicamente Escalonados*, evitando a “Falta de Conhecimento”.

5.2 – RECOMENDAÇÕES

Como recomendações para continuidade de investigações nesta linha de pesquisa, sugerem-se, entre outras possíveis, as seguintes:

- ✓ Testes de utilização de outros algoritmos de otimização na geração da *Biblioteca de Conhecimentos*, buscando a diminuição da “maldição” da dimensionalidade presente em vários algoritmos de programação dinâmica. O algoritmo de Programação Dinâmica Diferencial definido por JACOBSON (1970) é uma das alternativas. Algoritmos de programação quadrática também podem ser testados;
- ✓ Utilização, na geração da *Biblioteca de Conhecimentos (BC)*, de algoritmos estocásticos de otimização, aumentando as informações presentes na *BC*. Isso proporcionará aos modelos baseados em inteligência artificial um melhor “aprendizado” decorrente do maior número de exemplos disponíveis;
- ✓ Execução de análises de sensibilidade, em especial nos modelos baseados em redes neurais artificiais, estabelecendo relações de causa e efeito por meio da identificação da influência de cada variável de entrada em cada uma das variáveis de saída, reduzindo a “caixa preta” que caracteriza algumas dessas abordagens;
- ✓ Investigação de sistemas híbridos neuro-difusos que utilizem sistemas especialistas difusos do tipo Mamdani e partição difusa dos universos de domínio das variáveis, buscando a identificação, para esse tipo de abordagem, de estruturas adequadas ao tipo de problema estudado nesta pesquisa;
- ✓ Inclusão, na estrutura metodológica proposta para os modelos quali-quantitativos, de modelo formal de previsão climática fundamentado em aspectos do clima da região, verificando possíveis melhorias nos resultados.

REFERÊNCIAS BIBLIOGRÁFICAS

REFERÊNCIAS BIBLIOGRÁFICAS

1. Abrahart, R., See, L., Kneale, P.E.; 1999; “*Applying saliency analysis to neural network rainfall-runoff modeling*”. In: http://www.geovista.psu.edu/sites/geocomp99/Gc99/003/gc_003.htm
2. Aguiar, H. e Oliveira Jr. 1999; “*Lógica Difusa: Aspectos Práticos e Aplicações*”, Editora Interciência, Rio de Janeiro.
3. Alvim, A.M.; Chaudhry, F.H., Mello, C.E.F. e Naghettini, M.; “*Operação Otimizada de um Reservatório do Sistema de Abastecimento de Água de Belo Horizonte via Programação Dinâmica Estocástica*”, XV Simpósio Brasileiro de Recursos Hídricos, CD-ROM, 2003
4. Amiri, M., 2003; “*Fuzzy C-Means Clustering – Course Project Presentation*” In: http://mehr.sharif.edu/~amiri/Downloads/Y_FCMC/Y_FCMC_Presentation_Ver0.8.ppt.
5. Andreu, J., Capilla, J., Sanchis, E. 1991. “*AQUATOOL: a computer – assisted support system for water resources research management including conjunctive use*”. In: Loucks, D.P., Costa, J.R., ed. Decision support systems. NATO. P.333-355.
6. Aquino, Ronaldo R.B.; Carvalho Jr., Manoel A.; Souza; Benemar Alencar; “*Redes Neurais Artificiais: Uma Aplicação ao Planejamento da Operação de Sistemas Hidrotérmicos de Geração*” Proceedings of the IV Brazilian Conference on Neural Networks – IV Congresso Brasileiro de Redes Neurais, pp. 164-169, Jul/1999, Brasil.
7. Araújo, A.G.; 2004, “*Estimativa e Classificação da Compactação do Solo pelo Tráfego de Máquinas Agrícolas através da Modelagem Nebulosa*”, Tese de Doutorado, USP, 2004.
8. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology: 2000; “*Artificial Neural Networks in Hydrology: I: Preliminary Concepts*”; J. Hydrologic Engng, ASCE 5(2), pp. 115-123
9. Azevedo, J.R.G; da Silva; F.H.C.; Albuquerque, A.S.O.; Texeira, L.C.G.D.; “*Comparação entre Modelos Hidrológicos utilizando Redes Neurais Artificiais e por Regressão Linear Múltipla*”, VII Simpósio de Recursos Hídricos do Nordeste, 2004, CD-ROM.
10. Ballini, R.; França, E.; Kadowaki, M.; Soares, S.; Andrade, M.; “*Modelos de Redes Neurais e Box & Jenkins para Previsão de Vazões Médias Mensais*”. In: Simpósio Brasileiro de Recursos Hídricos, 12°. CD-ROM, 1997.
11. Baratti, R.; Cannas, B.; Fanni, A.; Pintus, M.; Sechi, G.M.; Toreno, N.; 2003; “*River flow forecast for reservoir management through neural networks*”; Neurocomputing 55 (2003), pp. 421-437.
12. Barbalho, V.M.S.; 2001; “*Sistemas baseados em Conhecimento e Lógica Difusa para Simulação do Processo Chuva-Vazão*”; Tese de Doutorado, UFRJ, 2001.
13. Bárdossy, A., Duckstein, L.; 1992; “*Analysis of a karstic aquifer management problem by fuzzy compositive programming*”; Water Resources Bulletin, 28 (1), pp. 63-73.

14. Bárdossy, A., Disse, M., 1993; “*Fuzzy rule-based models for infiltration*”; Water Resources Research 29 (2), pp. 373-382.
15. Bellman, R. E., Dreyfus, S. E. 1962. “*Applied dynamic programming*”. Princeton: Princeton University.
16. Bellman, Richard; 2003; “*Dynamic Programming*”; Dover Publications, Inc. New York (reimpressão da sexta edição de 1972 do original publicado em 1957 pela Princeton University Press).
17. Bertsekas, D.P.; 1995; “*Dynamic Programming and Optimal Control*”; Athena Scientific, Belmont, Massachusetts.
18. Bertsekas, D.P.; Tsitsiklis, J.N.; 1996; “*Neuro-Dynamic Programming*”; Athena Scientific, Belmont, Massachusetts.
19. Bhaskar, N., Whitlatch, E., 1980; “*Derivation of Monthly Reservoir Release Policies*”; Water Resources Res., 16 (6), pp. 987-993
20. Braga Júnior, B. P. F. 1983. “*Noções de programação dinâmica aplicada ao planejamento e operação de sistemas de recursos hídricos*”. In: CURSO de engenharia hidrológica. São Paulo: EPUSP: DAEE: ABRH. v.2, p.M.1 – M.14
21. Braga Junior, B. P. F. 1987. “*Técnicas de otimização e simulação aplicadas em sistemas de recursos hídricos*”. In: “Modelos para gerenciamento de recursos hídricos”. São Paulo: Nobel: ABRH. cap.5, p.427 – 517.
22. Câmara, E.P.; Cordeiro Netto, O.M.; 2003. “*Conjuntos Difusos – Aplicações à Operação de Reservatórios*”, XV Simpósio Brasileiro de Recursos Hídricos, CD-ROM.
23. Cancelliere, A.; Giuliano, G.; Ancarani, A.; Rossi, G.; 2002. “*A Neural Networks Approach for Deriving Irrigation Reservoir Operating Rules*”; Water Resources Management, 16, pp. 71-88.
24. Cancelliere, A.; Giuliano, G.; Nicolosi, V.; Rossi, G.; 2003. “*Optimal short-term operation of a multipurpose reservoir system under limited water supply*”; Water Resources System – Hydrological Risk, Management and Development (Proceedings of Symposium HS02b held during IUGG2003 at Sapporo, July, 2003). IAHS Publ. no. 281.
25. Chandramouli, V., Taman, H.; 2001; “*Multireservoir Modelling with Dynamic Programming and Neural Networks*”; Journal of Water Resources Planning and Management; Vol 127, No. 2, pp.89-98.
26. Chang, F.-J.; Chen, Y.-C, 2001; “*A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction*”; Journal of Hydrology 245, pp. 153-164.
27. Chow, V. T., Maidment, D. R., Tauxe, G.W. 1975. “*Computer time and memory requirements for DP and DDDP in water resource system analysis*”. Water Resources Research, Washington, v.11, n.5, p.621-628
28. Chung, I. and Helweg, O. (1985), “*Modeling the California State Water Project*”, Journal of Water Resources Planning and Management, Vol. 111, no. 1, pp. 83-97
29. Crawley, P.D., Dandy, G.C. 1993. “*Optimal operation of multiple-reservoir system.*” Journal of Water Resources Planning and Management, New York, v.119, n.1, p.1-17

30. Crespo, J.J; Mora, E. “*Drought estimation with neural networks*”. *Advances in Engineering Software*, n. 18, pp. 167-170, 1993.
31. Dorfman, R. 1962. “*Mathematical models: the multistructure approach*”. In: MAAS, A. et al. “*Design of water resource systems*” Cambridge: Harvard University. ch.13, p.494-539
32. Dos Santos, Cláudia Cristina “*Modelagem de Bacias Urbanas com Redes Neurais Artificiais*”; Dissertação de Mestrado, Escola Politécnica, USP, São Paulo, 2001
33. Dreyfus, S.E., Law, A.M. 1977. “*The art and theory of dynamic programming*”. New York: Academic Press.
34. Dubrovin, T; Jolma, A; Turunen, E; 2002 “*Fuzzy Model for Real-Time Reservoir Operation*”, *Journal of Water Resources Planning and Management*, Vol 128, N.1, pp. 66-73, ASCE.
35. Ellis, J.H., Revelle, C.S. 1988. “*A separable linear algorithm for hydropower Optimization*” *Water Resouces Bulletin*, Bethesda, v.24, n.2, p.435-447
36. Evans, J.R., Olson, D.L. 1998. “*Introduction to simulation and risk analysis*”. Englewood Cliffs: Prentice-Hall.
37. Faber, B.A.; Stedinger, J.R.; 2001; “*Reservoir optimization using sampling SDP with ensemble streamflow prediction (ESP) forecast*”; *Journal of Hydrology* 249 (2001) ; pp. 113-133.
38. Fontane, D.G.; Gates, T.K.; Moncada, E. (1997); “*Planning reservoir operations with imprecise objectives*”. *Journal of Water Resources Planning and Management*, 123 (3), pp. 154-162.
39. Foufoula-Georgiou, E., Kitanidis, P. K. 1988. “*Gradient dynamic programming for stochastic optimal control of multidimensional water resources systems*”. *Water Resources Research*, Washington, v.24, n.8, p.1345-1359.
40. French, M.N.; Krajewski, W.F; Cuykendall, R.R.; “*Rainfall forecasting in space and time using neural network*”; *Journal of Hydrology*, n. 137, pp. 1-31, 1992.
41. Fukuyama, Y., Sugeno, M., 1989, “*A new method of choosing the number of clusters for the fuzzy c-means method*” *Proceeding of 5th Fuzzy Syst.*, pp. 247-250
42. Gal, S. 1979. “*Optimal management of a multireservoir water supply system*”. *Water Resources Research* , v.15, n.4, p.737-749.
43. Galvão, C.O.; Ikebuchi, S.; Kojiri, T.; 1996. “*Reservoir Operation and Climate Forecasting in a Tropical Region*”, *Proceedings International Conference on Water Resources & Environment Research*, Vol. 2, p. 71-78, Out 29-31, Kyoto, Japan.
44. Galvão, C.O.; Valença, M.J.; 1999; “*Sistemas Inteligentes*”; Editora da Universidade (UFRGS) e ABRH (Associação Brasileira de Recursos Hídricos); 246p.
45. Ganoulis, J.G.; 1994; “*Engineering risk analysis of water pollution: probability and fuzzy sets*”; VCH – Weinheim, New York; Basel; Cambridge; Tokyo.
46. Giuliano, G., Cancelliere, A. And Rossi, G.; 2003(?) “*Operation of a Reservoirs System through Adaptive Fuzzy Inference System*”, XXX IAHR Congress.
47. Goldbarg, M.C.; Luna, H.P.L.; 2000; “*Otimização Combinatória e Programação Linear: Modelos e Algoritmos*” I Editora Campus. Brasil

48. Gondzio, J. Makowski, M. 1995. "Solving a class of LP problems with a primal-dual logarithmic Barrier method." *European Journal of Operational Research*, v.80, p.184-192.
49. Goodman, A. 1984. "Principles of water resources planning" Englewood Cliffs: Prentice-Hall.
50. Goulter, I.; Suharyanto; 1996? "Application of Fuzzy Inferencing Principles in Reservoir Operation Analysis", in: <http://bpps.ourfamily.com/artai006.html>, acessado em junho/2005.
51. Govindaraju, R.S. and Ramachandra Rao, A., 2000; "Artificial Neural Networks in Hydrology"; Klumer Academic Publishers, The Netherlands.
52. Grygier, J.C., Stedinger, J.R. 1985. "Algorithms for optimizing hydropower System operation". *Water Resources Research*, Washington, v.21, n.1, p.1-10
53. Gupta, A.P; Harboe, R.; Tabucanon, M.T.; 2000; "Fuzzy multiple-criteria decision making for crop area planning in Narmada river basin"; *Agricultural Systems* 63 (2000), pp. 1-18.
54. Haykin, S.; 2001; "Redes Neurais: Princípios e Prática"; Bookman, Porto Alegre.
55. Heidari, M., Chow, V.T., Kokotovic, P.V., Meredith, D.D. 1971. "Discrete Differential dynamic programming approach to water resources systems optimization". *Water Resources Research*, Washington, v.7, n.2, p.273-282.
56. Houck, M.H., Cohon, J.L. 1978. "Sequential explicitly stochastic linear Programming models: a proposed method for design and management of multipurpose reservoir systems". *Water Resources Research*, Washington, v.14 n.2, p.161-169
57. Houck, M. H., Datta, B. 1981. "Performance evaluation of a stochastic optimization model for reservoir design and management with explicit reliability criteria". *Water Resources Research*, Washington, v.17, n.4, p.827-832
58. Hsu, K.-L., Gupta, H.V.; Sorooshian, S.; 1995; "Artificial Neural Network modeling of the rainfall-runoff process"; *Water Resource Research* 31 (10), pp. 2517-2530.
59. Huang, W.-C.; 1996. "Decision support system for reservoir operation". *Water Resources Bulletin*, 32 (6), pp. 1221-1232.
60. Jacobson, D.H., Mayne, D.R. 1970. "Differential dynamic programming". New York: American Elsevier.
61. Jacoby H. D. and D. P. Loucks, 1972. "Combined use of optimization and simulation models in river basin planning"; *Water Resources Research*, Vol. 8(6), 1401-1414.
62. Jang, J.S.R.; 1993; "ANFIS: Adaptive-network-based fuzzy inference system"; *IEEE Transactions on Systems, Man and Cybernetics*, v. 23, n. 3, pp. 665-685.
63. Joeres, E.F., Seus, G. J., Engelman, H. M. 1981. "The Linear Decision Rule (LDR) reservoir problem with correlated inflows: 1. Model development". *Water Resources Research*, Washington, v.17, n.1, p.18-24.
64. Johnson, S.A; Stedinger, J.R; Stachus, K.; 1991, "Heuristic operating policies for reservoir system simulation"; *Water Resources Research*, Vol. 27 (5), pp. 673-685.

65. Karamouz, M.; Houck, M.H.; 1982; “*Annual and monthly Reservoir Operating Rules generated by deterministic optimization*”; Water Resources Research, Vol. 18(5), pp. 1337-1344
66. Karamouz, M.; Houck, H.; 1987. “*Comparison of Stochastic and Deterministic Dynamic Programming for Reservoir Operation Rule Generation*”; Water Resources Bull, 23 (1), pp. 1-9.
67. Karamouz, M.; Houck, M.H.;Delleur, J.W.; 1992; “*Optimization and Simulation of Multiple Reservoir Systems*”; Journal of Water Resources Planning and Management, Vol. 118 (1), pp. 71-81.
68. Karamouz, M., Vasiliadis, H.V. 1992. “*Bayesian stochastic optimization of reservoir operation using uncertain forecasts*”. Water Resources Research, Washington, v.28, n.5, p.1221-1232.
69. Karul, C.; Soyupak, S.; Çilesiz, A.; Akbay, N.; Gérmen, E.; 2000; “*Case studies on the use of neural networks in eutrophication modeling*”; Ecological Modelling 134 (2000), pp.145-152.
70. Kasabov, N.K.; 1998; “*Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering*”, A Bradford Book, MIT Press, Cambridge, Massachusetts.
71. Kelman, J., Stedinger, J.R., Cooper, L.^a, Hsu, E., Yuan, s-p. 1990. “*Sampling stochastic dynamic programming to reservoir operation.*” Water Resources Research, Washington, v.26, n.3, p.447-454.
72. Klir, G.J. and Yuan, B. (1995) “*Fuzzy sets and fuzzy logic – Theory and applications*” Prentice-Hall, Englewood Cliffs, N.J.
73. Kosko, B.; 1992; “*Neural Networks and Fuzzy Systems: A Dynamical Systems Approach to Machine Intelligence*”, Prentice Hall, Englewood Cliffs
74. Kuczera, G. 1989. “*Fast multireservoir multiperiod linear programming models*”. Water Resources Research, Washington, v.25, n.2, p.169-176.
75. Labadie, J.W. 1987. “*Otimização da operação de projetos agrícolas*”. Brasília: PRONI.
76. Lanna, A.E.L., Schwarzbach, H.S.R. 1989. “*MODHAC: Modelo Hidrológico Auto-Calibrável*”. Porto Alegre: Instituto de Pesquisa Hidráulica da UFRGS
77. Lima, H.V.C.; Lanna, A. E. L.; 2005; “*Modelos para Operação de Sistemas de Reservatórios: Atualização do Estado da Arte*”. Revista Brasileira de Recursos Hídricos, Brasil, v. 10, n. 3, 05-22.
78. Lima, L.C.T.M; Lima, H.V.C.L; Lima, C.H.R.; “*Modelagem por Redes Neurais Artificiais Aplicadas ao Processo Chuva-Vazão no Semi-Árido Cearense*”, In: VII Simpósio de Recursos Hídricos do Nordeste, 2004, CD-ROM
79. Lima, H.V.C; Lima, L.C.T.M; Lima, C.H.R; “*Modelagens Hidrológica Conceitual e Por Redes Neurais Artificiais Aplicadas ao Processo Chuva-Vazão: Uma Análise Comparativa*”, In: XVII Simpósio Brasileiro de Recursos Hídricos, 2005, CD-ROM
80. Loucks, D. P., Falkson, L.M. 1970. “*A comparison of some dynamic, linear and policy iteration methods for reservoir operation.*” Water Resources Bulletin, Bethesda, v.6, n.3, p.384-400

81. Loucks, D.P., Stedinger, J.R., Haith, D.A.; 1981. “*Water resource systems planning and analysis*” Englewood Cliffs: Prentice-Hall.
82. Luenberger, D. 1973. “*Introduction to linear and nonlinear programming*”. Reading: Addison-Wesley
83. Maceira, Maria Elvira P., Kelman, Jerson, 1989. “*Programação Dinâmica Amostral Aplicada a Operação de Reservatórios*”; In: X Seminário Nacional de Produção e Transmissão de Energia Elétrica, Curitiba.
84. Marinho, M.H.N.; Andrade Filho, M.G.A.; Ballini, R.; Santos, E.F. e Soares Filho, S.; “*Previsão de Vazões Afluentes utilizando Modelos Periódicos Auto-regressivos, Redes Neurais e Redes Neurais Nebulosas*”, VII Simpósio de Recursos Hídricos do Nordeste, 2004
85. Molinas, P.A., Tucci, C.E.M. 1989. “*Operação de um sistema de abastecimento d’água*”. In: Simpósio Luso-Brasileiro de Hidráulica e Recursos Hídricos, 4., 1989, Lisboa. Anais. Lisboa: APRH; [Rio de Janeiro]: ABRH. v. 2, p.121-131.
86. Molinas, P.A.; 1995; “*Estudo da Oferta Hídrica do Sistema de Abastecimento da Região Metropolitana de Fortaleza: Análise das Alternativas de Operação do Sistema*”; COGERH-CE (Boletim Interno).
87. Mousavi, S.J.; Karamouz, M.; 2003; “*Computational improvement for dynamic programming models by diagnosing infeasible storage combinations*”; *Advances in Water Resources* 26 (2003), pp. 851-859.
88. Murray, D.M., Yakowitz, S.J. 1979. “*Constrained differential dynamic programming and its application to multireservoir control.*” *Water Resources Research*, Washington, v.15, n.5, p.1017-1027.
89. Nandalal, K.D.W.; Sakthivadivel, R.; 2002; “*Planning and management of a complex water resource system: case of Samanalawewa and Udawalawe reservoirs in the Walawe river, Sri Lanka*”; *Agricultural Water Management* 57 (2002), pp. 207-221.
90. Neelakantan, T.R. and Pundakikanthan, N.V.; 2000. “*Neural Network-based Simulation-Optimization Model for Reservoir Operation*”; *Journal of Water Resources Planning and Management*, Vol 126, No. 2.
91. Nemhauser, G.L. 1966. “*Introduction to dynamic programming*”. New York: John Wiley
92. Ozden, M. 1984. “*A binary state DP algorithm for operation problems of multireservoir systems*” *Water Resources Research*, Washington, v.20, n.1, p.9-14
93. Pedrollo, Olavo C.; 2000; “*Previsão em Tempo Atual de Cheias com Sistema Especialista Difuso*”. Tese de Doutorado. IPH/UFRGS, 123p.
94. Pedrollo, O.; Lanna, A.E.L.; 2003; “*Previsão de Cheias em Tempo Real com Sistema Especialista Difuso*”, *RBRH – Revista Brasileira de Recursos Hídricos*, v.8, n.1, Jan/Mar 2003, pp. 45-60.
95. Pereira, B.J.C., Codner, G.P. 1996. “*Reservoir targets for urban water supply systems*”. *Journal of Water Resources Planning and Management*, New York, v.122 n.4, p.270-279.
96. Piccardi, C., Soncini – Serra, R. 1991. “*Stochastic dynamic programming for Reservoir optional control: dense discretization and inflow correlation assumption*

- made possible by parallel computing.*” Water Resources Research, Washington, v.27, n.5, p.729-741.
97. Porto, R.L.L (org), 1997. “*Técnicas quantitativas para o gerenciamento de recursos hídricos*”; Editora da Universidade, UFRGS, ABRH, Porto Alegre.
 98. Raman, H. and Chandramouli, V.; 1996; “*Deriving a General Operating Policy for Reservoir using Neural Network*”; Journal of Water Resources Planning and Management, ASCE 122 (5), pp 342-347.
 99. Righetto, A.M., Mattos, A.; “*Melhorias em um Sistema Urbano de Macrodrenagem – Aplicação de Conjuntos Difusos na Avaliação de Incertezas*”; XIII Simpósio Brasileiro de Recursos Hídricos, CD-ROM, 1999.
 100. Roefs, T.G., Bodin, L.D. 1970. “*Multireservoir operation studies*”. Water Resources Research, Washington, v.6, n.2, p.410-420.
 101. Rohn, M. C.; Costa, M.; do Nascimento, L.V.; Gibertoni, R.C.; Kaviski, E.; “*Sistema de Apoio à Decisão para Controle de Outorgas: uma Solução baseada em Redes Neurais Artificiais*”, XV Simpósio Brasileiro de Recursos Hídricos, CD-ROM, 2003.
 102. Ross, T.J; 2004; “*Fuzzy Logic with Engineering Applications*”, Joh Willey & Sons, Ltd, 2ed. 628p.
 103. Russell, S.O.; Campbell, P.F.; “*Reservoir operating rules with fuzzy programming*”; Journal of Water Resources Planning and Management, 122 (3), pp. 165-170
 104. Saad, M.; Bigras, P.; Tuegeon,A.; Duquette, R.; “*Fuzzy learning decomposition for the scheduling of hydroelectric power systems*”; Water Resources Research, 32 (1) pp. 179-186.
 105. Saad, M., Turgeon, A., Bigrs, P. Duquette, R. 1994. “*Learning disaggregation technique for the operation of long-term hydroelectric power systems.*” Water Resour. Res. 30 (1), pp. 3195-3202.
 106. Sarmiento, F.J. “*Modelagem de séries hidrológicas através de redes de neurônios*”. Revista Brasileira de Recursos Hídricos – RBRH, vol 1, n.2 pp. 19-31, 1996.
 107. Sasikumar, K.; Mujumdar, P.P. “*Fuzzy optimization model for water quality management of a river system*” Journal of Water Resources Planning and Management, May/June, 1996, pp. 165-170
 108. Shamseldin, A.Y. “*Application of a neural network technique to rainfall-runoff modeling*”. Journal of Hidrology, n. 199, pp. 272-294, 1997.
 109. Shrestha, B.; Duckstein, L.; Stakhiv, E.Z.; “*Fuzzy rule based modeling of reservoir operation*”; Journal of Water Resources Planning and Management, 122 (4), 262-269; 1996.
 110. Sigvaldason, O.T; 1976 “*A Simulation Model for Operating a Multipurpose Multireservoir System*”. Water Resources Research, 12, pp. 263-278.
 111. Silva Filho, Donato; Carneiro Adrano A. F.; Araújo, Aluizio F.R.; 1999. “*Redes RBF Aplicadas à Simulação da Operação de Usinas Hidroelétricas*” Proceedings of the IV Brazilian Conference on Neural Networks – IV Congresso Brasileiro de Redes Neurais, pp. 275-280.

112. Simonovic, S.P., Mariño, M.A. 1980. “*Reliability programming in reservoir management: 1. Single multipurpose reservoir*” *Water Resources Research*, Washington, v.16, n.5, p.844-848
113. Simonovic, S.P. 1992. “*Reservoir systems analysis: closing gap between theory and practice*”. *Journal of Water Resources Planning and Management*, New York, v.118, n.3, p.262-280
114. Smith, J., Eli, R.N. (1995). “*Neural network models for rainfall-runoff process*”. *J. Water Resour. Plng and Mgmt.*, ASCE, 121(6), pp.499-508.
115. Sniedovich, M. 1980. “*Analysis of a chance-constrained reservoir control model*”. *Water Resources Research*, Washington, v.16, n.5, p. 849-853
116. Sniedovich, M.; 1992; “*Dynamic Programming*”; Marcel Dekker, Inc. New York.
117. Sperb, R.M.; Modro, N.R.; Marcondes, P.; Foes, P.A.; Barcia, R.M.; Pacheco, R.C.S.; Tavares, G.; “*PREVENT: Protótipo de um Sistema de Previsão de Enchentes baseado em Redes Neurais*” XIII Simpósio Brasileiro de Recursos Hídricos, CDROM, 1999.
118. Strobel, O.M. 1983. “*Programação linear e método de restrições probabilísticas: um exemplo de aplicação*”. In: curso de engenharia hidrológica. São Paulo: EPUS: DAEE: ABRH. V.2, p.N.1-N.49
119. Sugeno, M.; Yasukawa, T., 1993; “*Fuzzy identification of systems and its application to modeling and control*”. *IEEE Trans. on Systems, Man and Cybernetic*, SMC-15, pp. 116-132.
120. Suharyanto; Bouchart, F.; Wasimi, S.A., Goulter, I.C.; 1996?. “*Sthocastic Fuzzy Dynamic Programming in Reservoir Operation Study*”; in: <http://bpps.ourfamily.com/artai009.html> acessado em junho/2005.
121. Tafik, M.; 2003; “*Linearity versus non-linearity in forecasting Nile River flows*”; *Advances in Engineering Software* (2003), pp. 515-524.
122. Tai, F-K., Goulter, I.C. 1987. “*A stochastic dynamic programming based approach to the operation of multi-reservoir system*”. *Water Resources Bulletin*, Bethesda, v.23, n.3, p.371-377
123. Takagi, T., Sugeno, M. 1985; “*Fuzzy identification of systems and its applications to modeling and control*”. *IEEE Trans. on Systems, Man, and Cybernetics*, 15; pp.116-132.
124. Tang, Z.; and Fishwick, P.A. (1993); “*Feedforward neural nets as models for time series forecasting*”; *J. Comp.* 5(4), 374-385.
125. Thirumalaiah, K.; Deo, M.C.; “*River stage forecasting using artificial neural networks*” *Journal of Hydrologic Engineering*, vol 3. no. 1, pp. 26-32, 1998
126. Tilmant, A.; Faouzi, E.H.; Vanclooster, M.; 2002 “*Optimal operation of multipurpose reservoirs using flexible stochastic dynamic programming*”; *Applied Soft Computing* 2 (2002), pp. 61-74.
127. Tilmant, A; Vanclooster, M; Duckstein, L; Persoons, E.; 2002b; “*Comparison of Fuzzy and Nonfuzzy Optimal Reservoir Operation Policies*”, *Journal of Water Resources Planning and Management*, Vol 128, N.6, pp. 390-398, ASCE, Dez/2002

128. Trezos, T., Yeh, W. W-G. 1987. “*Use of dynamic programming for reservoir Management*”. Water Resources Research, Washington, v.23, n.6, p.983-996.
129. Trott, W.J., Yeh, W. W-G. 1973. “*Optimization of multiple reservoir system.*” Journal of the Hydraulics Division American Society of Civil Engineers, New York, v.99, n.10, p.1865-1884.
130. Turgeon, A. 1980. “*Optimal operation of multireservoir power systems with stochastic inflows*”. Water Resources Research, Washington, v.16, n.2, p.275-283.
131. Turgeon, A. 1981. “*A decomposition method for the long-term scheduling of reservoirs in series*”. Water Resources Research, Washington, v.17, n.6, p.1565-1570.
132. Turgeon, A. 1982. “*Incremental dynamic programming may yield nonoptimal solutions.*” Water Resources Research, Washington, v.18, n.6, p.1599-1604.
133. Valença, M.J.S. 1997. “*Aplicação de Redes Neurais na Área de Recursos Hídricos*” In: Simpósio Brasileiro de Recursos Hídricos, 12^a. CD-ROM.
134. Valença, M.J.S; 1999; “*Aplicações de Redes Neurais*” in: “*Sistemas Inteligentes: aplicações a recursos hídricos e ciências ambientais*”; C. Galvão e M. Valença (org.), Ed. Universidade-UFRGS/ABRH. Porto Alegre.
135. Vasiliadis, H.V., Karamouz, M. 1994. “*Demand-driven operation of reservoirs using uncertainty-based optimal operating policies*”. Journal of Water Resources Planning and Management, New York, v.120, n.1, p.101-114.
136. Vieira, V.P.P.B; 1999; “*Avaliação quantitativa de riscos econômicos e ambientais*”; in: “*Sistemas Inteligentes: aplicações a recursos hídricos e ciências ambientais*”; C. Galvão e M. Valença (org.), Ed. Universidade-UFRGS/ABRH. Porto Alegre.
137. Vieira Neto, J.F. 1991. “*Dimensionamento ótimo do sistema de irrigação e barragens da bacia do rio Acarau-Ceará*”; Porto Alegre: Curso de Pós-Graduação em Recursos Hídricos e Saneamento. Dissertação (Mestrado Engenharia Civil).
138. Votrubá, L. 1988. “*Analysis of water resources systems*” Amsterdam: Elsevier.
139. Votrubá, L., Broza, V. 1989. “*Water management in reservoirs*” Amsterdam: Elsevier.
140. Wagner, H.M. 1969. “*Principles of operations research*”. Englewood Cliffs: Prentice-Hall
141. Windsor, J.S. 1973. “*Optimization model for the operation of flood control systems*”. Water Resources Research, Washington, v.9, n.5, p.1219-1226.
142. Wurbs, R.A. 1993. “*Reservoir system simulation and optimization models*”. Journal of Water Resources Planning and Management, New York, v.119, n.4, p.455-472
143. Wurbs, R.A; 1996. “*Modeling and analysis of reservoir system operations*”. Englewood Cliffs: Prentice-Hall
144. Xiong, L.; Shamseldin, A.Y.; O’Connor, K.M.; 2001; “*A non-linear combination of forecasts of rainfall-runoff models of the first-order Takagi-Sugeno fuzzy systems*” Journal of Hydrology 245, pp. 196-217.
145. Yakowitz, S. 1982. “*Dynamic programming applications in water resources*”. Water Resources Research, Washington, v.18, n.4, p.673-696

146. Yakowitz, S. 1989. "*Algorithms and computational techniques in differential dynamic programming*" Control and Dynamic Systems, v.31, p.75-91.
147. Yang, M., Read, E.G. 1999, "A *constructive dual DP for a reservoir model with correlation*", Water Resources Research, 21 (12), pp. 1797-1818.
148. Yeh, W. W-G. 1985. "*Reservoir management and operation models: a state-of-the-art Review*". Water Resources Research, Washington, v.21, n.12, p.1797-1818
149. Yin, Y.Y.; Huang, G.H.; Hipel, K.W.; "*Fuzzy relation analysis for multicriteria water resources management*"; Journal of Water Resources Planning and Management, Jan/Feb, 1999, pp. 41-47.
150. Yu, P-S.; Yang, T-C; "*Fuzzy multi-objective function for rainfall-runoff model calibration*", Journal of Hydrology, 238, pp. 1-14, 2000.
151. Zadeh, L.A., 1965; "*Fuzzy Sets*"; Information and Control. New York. Academic Press, V.8, pp. 338-353.
152. Zealand, C.M.; Burn, D.H.; Siminovic, S.P.; 1999; "*Short term streamflow forecasting using artificial neural networks*"; Journal of Hydrology 214, pp 32-48.
153. Zessler, U., 1989. "*Optimal operation of water distribution systems*" Journal of Water Resources Planning and Management, New York, v.115, n.6, p.735-752.

ANEXO I – BIBLIOTECA DE CONHECIMENTOS

A *Biblioteca de Conhecimentos* (Base de Dados) utilizada na obtenção das políticas operacionais pelos diversos tipos de abordagem foi obtida através de Programação Dinâmica Incremental (PDI). Visando permitir análises para diferentes situações hidrológicas, e tendo em vista a maldição da dimensionalidade presente em algoritmos de programação dinâmica, as séries históricas foram divididas em sub-séries – 17 no total – de 5 anos (60 meses). Os valores ótimos das retiradas para estas 17 sub-séries, e que em conjunto formam a *Biblioteca de Conhecimentos*, estão apresentado nas **Tabelas I.1 a I.3** a seguir.

Tabela I.1 – Biblioteca de Conhecimentos – Valores Ótimos das Retiradas do Açudes Pacoti/Riachão

Tabela I.1 – Biblioteca de Conhecimentos – Valores Ótimos das Retiradas do Açudes Pacoti/Riachão

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1912	0,502	0,463	5,710	5,826	4,205	4,128	5,671	5,980	5,440	5,980	5,826	6,057
1913	5,903	4,128	4,205	4,205	5,903	5,826	0,926	7,369	7,369	5,748	5,826	6,019
1914	5,826	1,427	6,250	4,244	3,395	4,938	6,520	5,826	5,864	4,437	6,906	6,134
1915	4,437	5,980	5,980	5,941	5,980	6,019	7,330	6,250	5,980	5,054	7,137	5,980
1916	4,514	3,781	4,630	4,205	5,787	5,671	4,938	6,366	4,938	7,060	5,170	5,054
1917	1,273	5,710	5,748	5,748	4,900	5,285	4,591	7,215	6,134	5,748	6,134	5,324
1918	6,481	4,977	5,748	3,048	2,083	7,677	5,131	7,523	5,864	5,440	5,247	7,099
1919	4,514	6,366	6,173	5,517	5,748	6,211	5,903	5,941	7,600	5,324	5,941	5,363
1920	5,941	6,983	4,321	4,244	4,282	4,205	6,134	6,674	5,941	4,977	7,022	5,440
1921	6,096	2,045	1,196	5,478	2,894	4,707	7,292	5,015	6,674	4,938	6,559	5,478
1922	4,282	5,864	6,019	4,090	4,128	4,514	5,633	4,630	5,440	5,671	5,903	6,019
1923	5,826	5,980	0,270	4,977	7,639	5,748	2,006	5,864	7,716	7,716	6,134	5,980
1924	5,941	4,205	2,353	2,855	3,588	4,282	5,710	7,292	4,167	5,864	5,941	6,057
1925	5,980	7,022	4,090	1,042	4,861	5,093	5,594	5,787	5,748	5,941	5,903	5,941
1926	6,057	6,057	0,694	4,244	5,478	5,170	4,977	5,748	5,980	5,980	5,903	6,019
1927	4,977	1,582	5,556	0,231	6,404	5,941	7,022	4,090	7,176	5,826	6,250	5,826
1928	4,514	2,122	6,327	6,173	4,437	7,292	5,131	6,404	5,980	5,093	6,019	5,440
1929	1,890	4,475	1,543	4,090	5,440	7,215	5,710	4,090	6,250	7,022	5,556	5,903
1930	2,662	7,562	3,781	6,559	5,478	5,826	6,443	6,944	6,019	6,134	5,710	5,633
1931	5,054	2,894	5,208	4,398	6,250	5,247	5,980	7,176	5,517	5,826	6,250	2,122
1932	0,502	7,215	7,639	5,826	6,019	6,327	7,253	5,980	4,900	5,980	6,867	5,170
1933	5,363	7,600	0,463	0,309	7,022	7,716	7,446	4,475	6,829	4,938	5,671	7,639
1934	4,321	5,787	4,167	2,585	4,321	6,867	2,199	7,639	3,511	6,597	7,716	6,906
1935	5,015	5,787	4,360	2,701	5,748	5,864	5,247	4,823	7,137	4,244	6,983	6,096
1936	5,671	5,285	5,941	2,276	6,289	7,677	7,716	7,677	5,594	5,826	5,903	4,977
1937	2,623	7,716	5,324	2,431	4,244	4,707	5,093	5,787	5,787	5,864	5,864	6,019
1938	6,096	5,941	4,090	4,090	4,977	5,054	6,019	4,707	5,826	5,826	6,019	5,980
1939	6,019	4,205	4,167	2,353	4,668	5,324	5,440	6,173	5,363	5,748	5,864	4,205
1940	7,716	6,019	2,199	1,273	5,980	4,938	6,481	3,048	6,983	5,787	6,019	5,980
1941	5,980	5,903	6,057	5,478	5,941	5,980	5,826	7,562	5,826	5,440	5,208	5,980
1942	4,321	6,019	5,941	5,015	5,170	5,787	7,485	5,440	6,597	4,244	6,520	5,594
1943	5,941	6,057	2,392	6,636	5,826	5,864	5,980	6,443	6,944	4,823	5,903	6,057
1944	5,556	4,398	7,677	1,042	7,677	5,787	7,137	4,977	7,022	5,864	4,475	2,238
1945	6,019	5,285	0,270	4,244	4,167	7,446	4,244	7,330	5,941	5,401	4,630	5,941
1946	6,096	1,813	7,215	5,671	4,437	5,285	5,671	5,748	5,903	6,019	5,864	5,903
1947	4,437	3,202	2,083	3,588	6,674	6,906	5,285	4,977	7,330	5,285	3,665	7,716
1948	6,327	5,980	4,977	2,469	7,639	5,401	6,752	6,134	4,823	6,134	7,176	4,977
1949	3,202	3,048	2,392	6,289	5,170	4,437	6,520	5,748	2,701	7,639	6,173	6,829
1950	4,205	5,941	4,244	4,090	5,787	5,864	4,090	4,437	7,716	5,903	6,250	6,520
1951	5,054	5,131	6,404	6,134	5,401	5,710	7,060	4,900	6,790	6,019	6,674	3,974
1952	4,745	1,659	5,440	4,167	4,745	5,594	5,864	6,983	5,401	5,285	7,407	4,900
1953	2,045	7,677	7,677	4,630	5,247	7,176	5,131	5,324	6,211	7,446	4,861	5,401

Tabela I.1 – Biblioteca de Conhecimentos – Valores Ótimos das Retiradas do Açudes Pacoti/Riachão

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1954	5,864	5,903	3,356	7,677	5,363	6,636	5,363	6,327	5,401	5,594	2,083	4,630
1955	3,819	7,600	4,167	2,662	5,710	5,787	6,790	4,938	6,559	5,015	5,941	7,407
1956	5,826	4,514	3,009	5,208	5,748	5,903	6,906	5,440	6,366	6,597	5,401	0,540
1957	5,324	1,350	2,932	4,437	4,167	6,944	7,022	5,826	5,131	5,131	7,523	4,938
1958	7,407	3,665	7,369	6,597	6,211	5,208	6,096	5,633	5,787	5,864	6,713	5,401
1959	6,289	2,894	5,980	1,427	7,407	5,324	5,787	5,671	5,941	6,057	6,019	5,980
1960	5,864	2,238	7,176	4,784	5,247	6,289	5,440	7,176	4,823	6,366	5,633	5,903
1961	5,864	4,552	4,282	2,122	5,864	5,941	5,633	6,983	4,244	5,980	5,787	6,057
1962	4,398	5,980	4,244	4,090	4,090	4,900	5,671	5,826	5,710	5,980	6,289	5,594
1963	5,941	4,167	4,128	4,205	4,090	5,903	5,633	5,671	5,787	5,980	5,864	6,096
1964	0,540	1,659	1,427	1,427	5,285	4,128	5,131	6,481	2,932	6,019	7,600	4,938
1965	6,983	7,485	4,437	1,312	2,508	5,633	5,710	4,090	6,597	5,633	6,443	5,633
1966	5,517	5,748	5,941	7,022	4,745	4,205	5,903	6,096	6,327	5,826	5,787	5,787
1967	4,282	0,386	1,312	4,090	4,167	5,401	4,437	7,407	5,941	4,128	7,639	4,630
1968	5,710	5,864	5,864	1,659	5,748	5,748	4,282	6,289	6,906	4,437	7,099	5,285
1969	5,285	6,057	3,472	4,205	5,054	4,668	4,707	5,787	7,407	4,475	6,559	6,520
1970	4,398	2,083	5,671	6,366	5,941	5,787	5,980	7,485	5,440	4,630	6,057	2,160
1971	5,980	5,980	6,520	0,386	4,167	5,247	5,401	6,134	4,398	5,826	6,019	5,941
1972	4,552	3,858	5,170	7,677	5,401	4,244	5,787	6,481	5,941	6,250	5,903	4,012
1973	6,713	4,244	4,167	4,090	4,552	1,466	4,861	3,819	7,485	5,787	4,090	7,716
1974	0,270	3,241	1,466	1,466	1,466	4,205	5,671	5,748	5,710	5,864	5,864	6,134
1975	5,748	4,745	0,617	4,282	1,235	5,054	4,861	2,469	6,443	7,639	5,826	6,559
1976	5,285	4,475	2,739	4,205	5,671	3,897	7,716	6,327	6,752	4,128	6,019	6,674
1977	0,463	4,745	6,481	0,347	0,926	1,042	5,324	4,591	3,819	7,716	5,864	5,980
1978	6,019	5,980	5,941	4,167	5,864	4,167	6,443	4,090	6,983	7,099	5,363	5,285
1979	6,019	2,199	7,407	7,716	0,540	7,639	7,716	6,134	5,941	6,636	5,015	6,057
1980	5,864	1,003	7,562	5,826	5,864	5,980	2,623	6,481	7,022	7,677	6,057	5,941
1981	2,816	5,478	5,517	5,093	5,864	5,710	5,903	6,867	5,517	5,941	5,517	5,941
1982	0,424	6,944	4,514	7,677	4,938	5,864	6,289	5,787	7,215	6,057	5,247	6,134
1983	4,900	3,395	7,716	6,481	5,440	6,019	7,330	5,556	6,829	5,247	4,012	7,099
1984	7,639	0,810	5,556	3,202	2,083	4,938	7,716	5,517	6,404	5,208	5,980	5,903
1985	5,980	0,270	4,205	4,205	4,167	4,437	4,167	5,748	5,594	5,903	5,864	5,903
1986	6,019	1,119	4,090	4,167	4,707	1,968	3,588	7,716	7,716	5,941	5,826	5,941
1987	2,816	3,704	4,282	5,170	5,671	4,398	5,710	5,826	5,864	5,903	5,941	7,060
1988	4,823	5,980	0,270	1,235	4,282	3,704	7,600	5,748	5,864	5,864	5,903	4,321
1989	7,639	6,289	1,929	0,309	4,205	3,395	7,253	4,205	5,633	5,826	5,903	5,980
1990	5,826	5,903	6,096	5,903	5,285	5,864	6,096	5,864	5,941	5,941	6,096	6,057
1991	5,903	3,395	4,128	1,235	6,867	5,748	5,594	5,787	5,826	5,980	5,903	6,057
1992	0,386	6,327	7,022	4,244	5,748	5,787	6,019	7,060	5,787	4,861	6,829	6,443
1993	6,134	4,938	5,710	5,826	5,826	5,903	6,983	6,019	6,790	5,941	5,864	3,125
1994	7,716	1,620	3,627	1,235	4,090	4,090	5,748	5,748	5,517	5,826	7,407	4,977
1995	5,401	6,134	4,167	4,167	4,514	4,090	5,594	5,748	6,559	5,556	5,401	7,060
1996	5,401	4,128	4,167	4,514	4,167	5,363	5,787	6,867	4,668	6,481	6,443	6,366

Tabela I.2 – Biblioteca de Conhecimentos – Valores Ótimos das Retiradas do Açude Pacajus

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1912	0,039	0,116	0,077	0,926	0,154	0,231	0,347	0,000	0,039	0,039	0,000	0,000
1913	0,000	0,116	0,154	0,154	0,154	0,772	0,772	0,463	0,000	0,000	0,000	0,000
1914	0,000	0,039	0,039	0,579	0,077	0,077	0,463	1,813	1,505	1,080	0,077	0,656
1915	0,039	0,116	0,231	0,231	0,039	0,077	1,505	2,392	2,083	2,739	2,778	2,894
1916	2,739	2,932	2,701	2,662	2,778	1,157	1,042	0,424	2,045	1,620	2,701	2,971
1917	1,157	0,116	0,733	0,733	0,154	1,968	1,968	0,116	0,000	0,039	0,039	0,039
1918	0,077	0,000	0,039	1,273	1,505	2,971	2,662	0,039	0,231	0,039	0,039	0,000
1919	0,309	0,000	0,039	0,077	0,193	0,231	0,154	0,116	0,077	0,039	0,039	0,077
1920	0,000	0,039	1,080	0,540	0,116	1,736	0,039	0,000	0,116	0,000	0,000	0,039
1921	0,000	0,193	0,579	2,006	2,122	1,698	0,579	2,045	0,424	0,116	0,000	0,039
1922	0,154	0,039	0,039	0,039	0,347	0,347	1,389	0,154	0,154	0,077	0,077	0,424
1923	1,042	1,968	1,968	2,971	1,003	0,116	0,000	0,000	0,000	0,000	0,077	0,077
1924	0,077	0,116	0,193	0,193	0,270	0,154	1,582	0,039	0,000	0,077	0,039	0,077
1925	0,000	0,154	0,193	0,154	0,077	0,116	0,000	0,039	0,039	0,039	0,039	0,039

Tabela I.2 – Biblioteca de Conhecimentos – Valores Ótimos das Retiradas do Açude Pacajus

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1926	0,000	0,039	0,000	0,116	0,231	0,154	0,000	0,039	0,116	0,039	0,000	0,039
1927	2,739	0,270	1,080	1,427	0,849	1,427	2,431	2,546	0,849	1,698	2,392	0,077
1928	0,849	2,894	2,971	2,778	2,855	2,971	2,855	2,855	2,932	2,894	2,971	2,894
1929	2,971	2,971	2,932	2,894	2,855	2,585	2,971	2,971	2,971	2,971	2,971	2,971
1930	2,971	2,971	2,971	2,971	2,971	2,971	2,932	2,971	2,971	2,932	2,971	2,971
1931	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971
1932	0,347	0,000	0,386	0,733	0,039	0,694	0,887	0,810	2,932	2,546	2,778	2,508
1933	2,894	2,392	0,309	1,157	0,733	2,199	0,849	0,077	0,039	0,039	0,000	0,000
1934	0,039	0,116	0,039	0,077	0,116	0,617	1,273	0,347	0,039	0,077	0,000	0,000
1935	0,000	0,039	0,579	0,039	1,080	0,077	1,080	2,045	2,623	2,585	2,199	2,701
1936	2,431	2,623	2,855	2,971	2,083	2,932	2,894	2,855	2,816	2,894	2,932	2,431
1937	2,083	0,039	0,463	0,116	2,546	0,386	0,502	0,154	0,231	0,309	0,386	0,386
1938	0,039	0,849	1,852	0,386	2,971	2,122	2,932	0,039	0,116	0,270	0,810	0,231
1939	0,579	2,585	0,694	1,235	1,582	0,502	0,077	0,116	0,116	0,077	0,309	0,270
1940	1,505	0,077	2,122	0,116	2,932	0,926	2,816	2,508	2,778	2,238	2,971	2,971
1941	2,971	2,932	2,894	2,971	2,932	2,701	0,579	2,585	2,971	2,816	2,971	2,855
1942	2,160	1,235	0,965	2,855	2,855	2,778	2,508	2,353	2,855	2,971	2,816	2,932
1943	2,971	2,971	2,701	2,855	2,392	2,353	2,431	0,887	2,623	2,971	2,585	2,971
1944	2,932	2,816	2,855	2,971	2,971	1,466	2,006	2,623	1,582	2,353	2,469	2,971
1945	1,080	0,154	0,039	0,039	0,077	1,929	1,736	0,000	0,193	0,579	0,000	0,154
1946	0,039	0,000	0,039	0,193	0,231	0,733	0,424	0,077	1,042	0,077	0,116	0,270
1947	2,932	2,971	2,971	2,932	2,932	2,971	2,971	2,971	2,971	2,971	2,971	2,971
1948	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971
1949	2,971	2,971	1,312	0,154	0,116	0,193	1,505	0,000	0,000	0,000	0,116	0,000
1950	0,116	0,000	0,039	0,039	0,926	1,157	2,971	2,971	2,971	2,971	2,971	2,971
1951	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971
1952	2,971	2,971	2,932	2,932	2,932	2,971	2,971	2,971	2,971	2,971	2,971	2,971
1953	2,971	2,971	2,932	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971
1954	2,971	2,971	2,971	2,971	2,932	2,971	2,971	2,971	2,971	2,971	2,971	2,971
1955	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971
1956	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971	2,971
1957	1,582	1,003	2,160	2,083	1,080	2,469	0,733	1,466	0,270	0,849	1,196	0,154
1958	0,579	0,386	0,347	0,926	1,003	1,080	0,270	0,193	0,039	0,347	0,116	0,965
1959	0,154	1,350	2,855	1,852	2,006	0,579	2,353	1,968	0,733	0,965	1,929	1,042
1960	0,579	0,000	0,270	2,546	2,662	2,546	1,813	0,270	2,315	2,546	1,582	2,816
1961	2,122	1,775	1,775	0,926	0,965	0,772	0,231	0,309	0,000	0,077	0,000	0,039
1962	0,039	0,772	0,617	0,193	0,270	0,193	0,000	0,039	0,000	0,039	0,154	0,000
1963	0,116	0,077	0,270	0,077	0,502	0,231	2,045	0,000	0,000	0,000	0,039	0,000
1964	0,231	0,154	0,694	0,694	0,039	1,196	1,466	0,039	0,039	0,000	0,000	0,000
1965	0,000	0,039	0,039	0,463	0,116	0,039	1,273	0,694	0,694	1,505	1,350	1,813
1966	2,855	2,315	2,585	2,778	2,508	2,971	2,662	2,353	2,894	2,971	2,894	2,932
1967	0,039	0,000	0,077	0,540	0,965	0,810	0,077	0,116	0,000	0,000	0,000	0,000
1968	0,000	0,039	0,039	0,347	0,077	0,077	0,579	0,000	0,270	0,077	0,000	0,231
1969	0,000	0,193	0,000	0,193	0,733	0,154	1,350	0,309	0,231	0,077	0,000	0,039
1970	0,000	0,039	0,000	0,000	0,039	0,000	0,039	0,000	0,116	0,000	0,116	0,077
1971	0,077	0,000	0,000	0,231	0,386	0,270	0,656	0,656	0,000	0,116	0,000	0,000
1972	0,077	0,270	0,000	0,000	0,000	0,077	0,656	0,386	0,463	0,579	2,816	2,932
1973	2,546	2,276	0,077	0,039	0,231	0,154	1,080	1,042	0,077	0,039	0,309	0,039
1974	0,116	0,116	0,154	0,154	0,154	1,389	1,157	0,077	0,000	0,231	0,039	0,116
1975	0,116	0,154	1,389	0,039	0,077	1,698	0,309	0,926	0,193	0,347	0,000	0,077
1976	0,039	0,000	0,077	0,579	0,231	0,386	0,424	0,039	0,000	0,000	0,154	0,039
1977	0,617	0,231	0,154	1,968	1,196	0,926	0,386	0,617	0,077	0,231	0,116	2,816
1978	2,894	2,238	2,778	2,816	2,971	2,045	0,116	1,003	0,309	0,000	0,231	1,736
1979	2,778	2,778	1,890	2,276	2,894	2,855	2,662	2,662	2,971	2,971	2,739	2,971
1980	2,932	2,971	2,971	2,122	1,543	1,273	0,231	0,617	1,312	2,739	2,932	2,855
1981	2,855	2,932	2,971	2,932	2,662	0,270	0,077	0,424	0,463	2,739	2,662	2,932
1982	2,623	1,929	2,623	2,469	1,698	2,469	2,276	2,894	0,887	2,816	2,160	2,508
1983	2,855	2,778	2,855	2,932	2,816	2,971	2,971	2,816	2,623	2,662	2,894	2,855
1984	2,623	1,350	0,579	0,463	0,579	0,540	0,309	0,926	0,309	0,154	0,000	0,039
1985	0,077	0,039	2,083	2,083	1,080	1,389	1,350	1,350	0,000	0,116	0,077	0,000
1986	0,000	0,000	1,620	1,813	1,813	0,810	2,315	1,042	0,000	0,116	0,000	0,000
1987	0,810	1,119	1,543	2,778	0,849	1,813	0,733	0,116	0,077	1,698	2,894	2,894
1988	2,932	2,894	2,855	2,894	2,971	2,971	0,116	0,193	0,077	0,077	0,000	2,778
1989	1,157	2,469	2,508	2,546	2,971	2,701	2,894	0,154	0,154	0,000	0,039	0,810
1990	1,389	0,386	1,042	0,039	1,196	2,083	0,810	2,971	2,855	2,932	2,855	2,855

Tabela I.2 – Biblioteca de Conhecimentos – Valores Ótimos das Retiradas do Açude Pacajus

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1991	2,932	2,971	2,894	2,932	2,971	0,347	0,039	0,154	2,392	2,971	2,932	2,855
1992	2,392	2,199	1,698	2,276	1,119	2,585	2,816	2,546	2,778	2,894	2,585	2,701
1993	2,932	2,971	2,971	2,855	2,932	2,739	2,971	2,971	2,971	2,855	2,971	2,971
1994	2,623	1,620	0,000	0,039	1,235	0,077	0,077	0,039	0,000	0,039	0,077	0,000
1995	0,000	0,000	0,039	0,154	2,045	0,039	0,039	0,000	0,000	0,039	0,000	0,039
1996	0,000	0,000	0,000	0,154	0,116	1,003	2,199	0,000	0,077	0,039	0,000	0,077

Tabela I.3 – Biblioteca de Conhecimentos – Valores Ótimos das Retiradas do Canal do Trabalhador

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1912	0,000	0,039	0,039	0,849	0,000	0,077	0,347	1,968	2,932	2,894	3,395	3,742
1913	0,116	0,000	0,000	0,000	0,039	0,733	0,116	2,971	3,742	3,588	1,350	3,164
1914	0,887	0,039	0,000	0,579	0,077	0,039	0,309	4,321	3,588	2,431	1,505	0,000
1915	0,116	0,502	0,077	1,659	3,164	2,778	3,858	2,701	3,511	3,086	1,620	4,321
1916	4,360	4,205	1,620	1,852	0,077	0,193	1,003	1,582	0,386	3,009	0,810	0,193
1917	0,000	0,077	0,694	0,694	0,039	1,852	1,080	1,698	4,167	4,012	3,897	0,077
1918	2,662	0,309	0,077	1,235	0,424	1,890	3,434	3,897	0,540	1,659	0,077	0,000
1919	3,897	0,386	2,662	2,546	0,424	3,356	3,164	3,472	3,549	0,039	3,588	1,813
1920	1,736	0,039	0,965	0,540	0,039	0,231	0,849	3,897	4,090	2,508	2,238	2,739
1921	2,392	0,154	0,463	1,929	2,083	1,659	0,540	1,736	4,360	1,312	2,855	0,000
1922	0,000	1,157	0,116	0,000	0,154	0,000	0,039	0,000	2,238	0,309	1,736	0,039
1923	0,309	0,270	0,039	0,193	0,039	0,039	2,006	1,582	4,514	0,386	3,395	0,039
1924	0,116	0,077	0,116	0,116	0,116	0,000	1,427	2,006	1,543	1,852	1,505	1,273
1925	0,039	1,929	0,000	0,077	0,000	0,000	1,582	0,617	2,623	2,238	1,466	0,077
1926	0,039	0,039	0,000	0,116	0,077	0,039	0,000	2,045	1,042	0,116	1,736	0,000
1927	0,000	1,929	0,733	2,894	0,077	1,157	3,511	0,579	3,472	2,238	4,090	0,810
1928	3,048	1,852	0,000	2,508	1,736	1,119	3,279	3,318	3,125	2,778	2,469	2,469
1929	3,897	2,006	0,579	1,235	1,813	2,392	4,244	3,202	2,701	4,977	4,630	4,977
1930	2,778	3,164	4,244	2,701	4,823	3,395	4,977	4,552	4,630	4,977	4,784	3,974
1931	4,437	4,630	4,630	2,160	2,546	2,971	4,514	4,514	4,475	4,475	1,736	3,086
1932	0,000	4,398	2,160	1,543	0,579	2,623	0,039	1,157	1,119	0,887	0,772	1,003
1933	2,431	2,855	1,119	1,042	0,617	2,083	3,202	2,623	3,897	2,662	2,855	1,042
1934	3,511	0,463	0,039	0,000	0,077	0,540	0,000	4,745	2,083	1,196	1,003	0,887
1935	1,466	0,077	0,502	0,039	1,042	0,039	0,887	2,276	4,244	2,431	1,620	4,282
1936	3,511	3,048	2,546	2,238	4,552	4,128	2,894	4,128	4,090	0,965	1,620	0,270
1937	0,000	0,000	0,039	0,039	0,077	0,039	0,077	2,122	3,781	0,039	0,039	0,039
1938	0,039	0,000	0,039	0,077	1,736	0,039	0,424	0,193	1,698	0,154	0,039	0,039
1939	0,077	0,077	0,039	0,039	0,039	0,116	0,077	0,965	2,238	3,318	0,772	0,039
1940	0,039	0,077	0,000	0,000	0,039	0,000	0,000	1,620	2,469	3,781	0,424	3,704
1941	2,894	1,813	0,193	2,855	0,386	1,736	2,469	0,694	4,630	3,549	1,968	1,543
1942	0,000	1,157	3,279	4,630	2,353	1,929	2,122	2,083	3,549	4,012	0,926	4,205
1943	3,511	2,932	3,125	0,116	0,849	3,241	3,781	3,511	1,968	1,273	2,469	1,659
1944	1,350	2,508	3,665	0,733	1,852	0,116	3,704	2,392	3,704	2,855	3,202	1,698
1945	0,116	0,000	0,039	0,039	0,077	1,813	0,540	0,502	2,392	4,012	3,279	0,039
1946	0,077	0,077	0,000	0,039	0,077	0,039	1,157	1,389	0,039	0,039	0,116	0,039
1947	0,000	2,971	2,160	2,122	2,160	2,160	2,160	4,360	4,475	2,662	4,514	3,858
1948	3,009	3,009	2,199	2,199	2,160	2,199	4,012	4,205	4,437	4,398	4,282	4,475
1949	3,009	2,971	1,273	0,116	0,039	0,039	1,196	3,395	3,279	2,623	3,588	0,887
1950	0,000	1,582	0,000	0,039	0,849	0,887	2,160	4,205	4,707	4,437	4,128	4,437
1951	2,971	2,971	2,971	1,929	2,739	2,160	2,276	4,552	4,475	4,668	4,128	3,858
1952	0,000	2,971	2,508	3,588	0,694	2,894	3,819	4,707	4,514	4,630	3,819	4,630
1953	2,778	1,427	3,395	2,623	1,350	3,009	4,823	4,823	4,977	4,977	4,784	3,897
1954	4,514	4,938	2,662	2,585	4,977	4,861	4,630	4,668	4,938	4,938	1,736	4,398
1955	2,585	2,392	2,623	0,502	0,926	0,965	1,157	4,707	4,090	4,861	4,167	4,437
1956	2,276	2,623	0,926	0,926	0,926	1,890	2,546	3,935	4,630	4,784	4,745	4,244
1957	0,000	0,926	0,039	0,733	0,000	0,039	1,659	0,000	0,039	0,000	0,000	0,039
1958	0,039	0,039	0,000	0,039	0,000	0,039	0,000	0,039	0,000	0,039	0,039	0,000
1959	0,000	0,000	0,000	0,000	0,039	0,039	0,039	0,000	0,000	0,000	0,000	0,039
1960	0,000	0,309	0,000	0,039	0,039	0,231	0,039	0,270	0,039	0,039	0,000	0,000
1961	1,003	1,698	1,775	0,849	0,926	0,694	0,039	3,434	3,665	3,511	3,819	0,000
1962	0,000	0,039	0,502	0,077	0,000	0,039	2,045	2,508	3,202	2,508	1,813	0,849

Tabela I.3 – Biblioteca de Conhecimentos – Valores Ótimos das Retiradas do Canal do Trabalhador

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1963	1,350	0,039	0,231	0,039	0,502	0,039	2,315	2,932	2,855	2,315	1,698	2,932
1964	0,231	0,000	0,656	0,656	0,000	1,157	1,427	0,000	2,160	4,668	0,231	2,083
1965	0,463	2,238	0,849	0,424	0,000	0,000	0,039	0,116	2,546	4,244	0,656	1,968
1966	3,974	3,704	4,900	3,395	4,012	3,974	4,244	1,389	4,514	2,508	3,048	2,623
1967	0,000	0,579	0,000	0,540	0,926	0,733	0,000	1,659	3,048	3,742	2,701	3,395
1968	1,080	0,270	0,039	0,270	0,000	0,039	0,039	0,270	2,546	0,000	0,231	0,810
1969	0,926	0,039	1,543	0,077	0,579	0,000	0,039	0,039	1,235	0,039	0,540	0,887
1970	1,775	0,694	1,312	1,273	0,039	0,617	0,887	0,039	0,000	0,077	0,000	0,039
1971	0,039	2,006	1,505	0,039	0,270	0,270	0,617	0,926	2,546	1,582	1,698	1,659
1972	0,000	0,887	2,894	4,244	0,463	2,122	2,546	1,698	2,932	1,659	2,353	3,434
1973	2,122	0,000	0,077	0,039	0,116	0,039	0,926	0,849	2,894	3,511	1,350	1,659
1974	0,000	0,039	0,039	0,039	0,039	1,196	0,116	0,039	3,125	2,469	1,389	1,312
1975	0,116	0,000	1,312	0,039	0,000	1,543	0,231	1,273	3,588	3,202	1,775	1,350
1976	0,039	0,000	0,077	0,386	0,000	0,193	2,739	2,238	3,395	0,039	3,279	0,154
1977	0,000	0,733	4,128	0,000	0,000	0,000	0,000	0,347	3,318	2,199	2,276	0,656
1978	1,273	0,116	0,077	0,424	2,045	1,080	1,620	3,742	0,039	3,897	3,511	4,090
1979	3,434	3,819	3,742	3,356	2,431	1,350	3,897	4,167	4,205	2,508	1,389	3,858
1980	3,704	0,000	2,006	0,309	1,505	0,077	3,781	3,395	2,816	3,897	3,627	3,665
1981	2,006	1,389	0,347	1,119	1,273	1,157	1,968	3,511	0,617	1,659	3,279	3,356
1982	0,000	2,122	4,321	2,392	1,427	3,665	4,668	4,051	4,591	4,938	3,974	4,475
1983	2,739	2,778	4,321	4,051	3,742	4,977	2,469	4,051	4,012	4,591	3,781	3,627
1984	3,202	2,045	1,968	0,386	0,502	0,386	0,231	0,926	2,855	1,003	3,819	1,698
1985	1,852	0,000	2,045	2,045	0,926	1,235	1,312	1,312	3,241	1,659	1,350	0,193
1986	1,350	1,505	1,543	1,736	1,775	0,694	2,238	1,003	2,816	2,199	1,852	0,077
1987	0,000	1,929	0,116	0,039	0,386	1,968	3,356	3,241	0,656	1,235	0,193	1,968
1988	3,511	2,739	3,202	0,733	0,926	0,116	0,000	3,241	1,235	0,116	0,077	0,039
1989	0,154	0,000	0,000	1,119	0,579	0,656	0,502	0,000	3,511	2,160	0,424	2,623
1990	2,238	3,048	0,154	2,623	1,466	0,039	3,434	4,282	1,582	1,505	1,505	0,270
1991	3,704	3,356	2,431	0,000	0,116	0,270	2,238	2,971	3,395	3,588	0,579	0,116
1992	0,000	4,552	1,736	0,000	1,775	2,199	3,781	2,006	2,238	0,887	4,977	1,890
1993	4,398	4,360	2,816	4,591	3,935	3,819	3,048	1,852	3,511	4,475	2,623	2,623
1994	3,125	3,588	0,116	0,000	1,042	0,000	0,039	0,000	1,659	2,623	1,543	0,116
1995	1,852	0,077	0,039	0,000	2,006	0,000	0,000	2,122	1,620	0,463	1,273	0,270
1996	0,039	1,119	0,000	0,000	0,116	0,772	4,167	1,466	0,000	0,347	1,890	0,077

ANEXO II – MODELAGEM POR LÓGICA DIFUSA – ANÁLISE DOS AGRUPAMENTOS

Tabela II.1a – Agrupamentos – Coeficientes de Eficiência – Retirada dos Açúdes Pacoti/Riachão – Modelo MBaseSED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	8.8605	1	0
2	0.7280	0.7587	0.2587
3	-0.4450	0.6229	0.2896
4	-2.3382	0.6171	0.3671
5	-2.7593	0.5722	0.3722
6	-2.8479	0.5458	0.3791
7	-2.8928	0.5213	0.3785
8	-3.1457	0.5168	0.3918
9	-3.2171	0.5150	0.4039

Tabela II.1b – Agrupamentos – Coeficientes de Eficiência – Retirada do Açúde Pacajus – Modelo MBaseSED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	20.5548	1	0
2	-7.8005	0.8598	0.3598
3	-9.6481	0.7688	0.4354
4	-12.0794	0.7194	0.4694
5	-12.2881	0.6865	0.4865
6	-11.8661	0.6377	0.4710
7	-12.7783	0.6585	0.5156
8	-12.6534	0.6440	0.5190
9	-12.7375	0.6416	0.5305

Tabela II.1c – Agrupamentos – Coeficientes de Eficiência – Retirada do Canal do Trabalhador – Modelo MBaseSED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	13.4264	1	0
2	0.2287	0.7541	0.2541
3	-3.0191	0.6679	0.3346
4	-4.4733	0.6144	0.3644
5	-5.0415	0.5791	0.3791
6	-5.5677	0.5634	0.3968
7	-5.4398	0.5359	0.3930
8	-6.3616	0.5650	0.4400
9	-6.1685	0.5303	0.4192

Tabela II.2a – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada dos Açúdes Pacoti/Riachão – Modelo MBaseSED

Antecedente	Conseqüente
Volume Total do Sistema*	Retirada do Pacoti/Riachão*
0,4287	0,6227
0,5796	0,5094
0,6836	0,5179
0,6757	0,6723
0,6063	0,6065
0,5412	0,605
0,6818	0,595
0,4431	0,5286
0,4692	0,3556

* Valores Normalizados

Tabela II.2b – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Açude Pacajus – Modelo MBaseSED

Antecedente	Conseqüente
Volume Total do Sistema*	Retirada do Pacajus *
0,4621	0,324
0,5342	0,6867
0,4062	0,6801
0,5928	0,315
0,6729	0,4829
0,6388	0,6829
0,6791	0,319

* Valores Normalizados

Tabela II.2c – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Canal do Trabalhador – Modelo MBaseSED

Antecedente	Conseqüente
Volume Total do Sistema*	Retirada do Canal do Trabalhador *
0,6726	0,4455
0,4465	0,4656
0,4508	0,6156
0,5831	0,5338
0,4581	0,3178
0,5941	0,3147
0,684	0,3145
0,6529	0,6262

* Valores Normalizados

Tabela II.3a – Agrupamentos – Coeficientes de Eficiência – Retirada dos Açudes Pacoti/Riachão – Modelo M01SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	20.1991	1	0
2	6.6298	0.6630	0.1630
3	3.5781	0.4968	0.1634
4	1.5528	0.4368	0.1868
5	0.6780	0.3738	0.1738
6	-0.8699	0.3733	0.2066
7	-1.4199	0.3596	0.2167
8	-1.7630	0.3474	0.2224
9	-1.6921	0.3208	0.2097

Tabela II.3b – Agrupamento – Coeficientes de Eficiência – Retirada do Açude Pacajus – Modelo M01SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	31.8934	1	0
2	2.0613	0.7615	0.2615
3	-0.9314	0.5971	0.2637
4	-3.0007	0.5077	0.2577
5	-3.8308	0.4568	0.2568
6	-5.2161	0.4390	0.2723
7	-4.3138	0.3812	0.2384
8	-5.5787	0.3803	0.2553
9	-6.0657	0.3678	0.2567

Tabela II.3c – Agrupamento – Coeficientes de Eficiência – Retirada do Canal do Trabalhador– Modelo M01SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	24.7650	1	0
2	8.3371	0.6490	0.1490
3	2.9566	0.5343	0.2010
4	1.5672	0.4339	0.1839
5	-0.0627	0.3917	0.1917
6	-0.6700	0.3573	0.1907
7	-1.9923	0.3541	0.2113
8	-2.1758	0.3318	0.2068
9	-2.2985	0.3144	0.2033

Tabela II.4a – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada dos Açudes Pacoti/Riachão– Modelo M01SED

Antecedentes			Conseqüente
Volume do Pacajus*	Volume do Pacoti/Riachão*	Volume do Gavião*	Retirada do Pacoti/Riachão*
0,4023	0,4393	0,5904	0,5749
0,5738	0,5131	0,5709	0,4483
0,6784	0,6661	0,5765	0,5989
0,6332	0,5536	0,3451	0,6002
0,6158	0,5362	0,63	0,5805
0,6829	0,6635	0,6585	0,548
0,6542	0,3901	0,5981	0,5938
0,6206	0,5912	0,577	0,6064

* Valores Normalizados

Tabela II.4b – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Açude Pacajus– Modelo M01SED

Antecedentes			Conseqüente
Volume do Pacajus*	Volume do Pacoti/Riachão*	Volume do Gavião*	Retirada do Pacajus*
0,5692	0,3951	0,5854	0,6603
0,6796	0,6613	0,5926	0,3311
0,5002	0,4679	0,5297	0,3693
0,6422	0,6228	0,5842	0,6531
0,6446	0,5679	0,583	0,3248
0,5862	0,5259	0,6141	0,6705

* Valores Normalizados

Tabela II.4c – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Canal do Trabalhador– Modelo M01SED

Antecedentes			Conseqüente
Volume do Pacajus*	Volume do Pacoti/Riachão*	Volume do Gavião*	Retirada do Canal do Trabalhador*
0,6821	0,6633	0,5973	0,3276
0,6259	0,5745	0,5816	0,3303
0,4256	0,4412	0,5952	0,3964
0,6363	0,4201	0,6112	0,547
0,6304	0,593	0,6172	0,5983
0,6641	0,6413	0,5883	0,4657
0,6267	0,5222	0,3566	0,3734

* Valores Normalizados

Tabela II.5a – Agrupamentos – Coeficientes de Eficiência – Retirada dos Açudes Pacoti/Riachão – Modelo M02SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	35.8190	1	0
2	11.0877	0.6643	0.1643
3	6.0410	0.4914	0.1581
4	2.2697	0.4300	0.1800
5	0.8420	0.3524	0.1524
6	0.2631	0.2980	0.1313
7	-0.4711	0.2767	0.1339
8	-0.8908	0.2556	0.1306
9	-1.0183	0.2333	0.1222

Tabela II.5b – Agrupamentos – Coeficientes de Eficiência – Retirada do Açude Pacajus – Modelo M02SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	47.5192	1	0
2	12.2467	0.6891	0.1891
3	5.1010	0.5464	0.2130
4	1.6653	0.4479	0.1979
5	-0.0312	0.3972	0.1972
6	-1.4507	0.3478	0.1811
7	-1.4151	0.3125	0.1696
8	-2.6977	0.2864	0.1614
9	-3.2672	0.2719	0.1608

Tabela II.5c – Agrupamentos – Coeficientes de Eficiência – Retirada do Canal do Trabalhador – Modelo M02SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	40.4361	1	0
2	14.7963	0.6231	0.1231
3	7.9287	0.4744	0.1411
4	4.6355	0.3886	0.1386
5	2.0470	0.3466	0.1466
6	1.0904	0.3061	0.1395
7	0.1452	0.2836	0.1408
8	-0.1841	0.2490	0.1240
9	-0.3453	0.2274	0.1163

Tabela II.6a – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada dos Açudes Pacoti/Riachão – Modelo M02SED

Antecedentes						Consequente
Volume do Pacajus em t*	Volume do Pacajus em t-1*	Volume do Pacoti/Riachão em t*	Volume do Pacoti/Riachão em t-1*	Volume do Gavião em t*	Volume do Gavião em t-1*	Retirada do Pacoti/Riachão*
0,6096	0,5659	0,5094	0,4896	0,4423	0,4644	0,5591
0,6289	0,6282	0,5533	0,5567	0,6002	0,5947	0,5739
0,6231	0,6228	0,5821	0,5867	0,5832	0,5823	0,5857
0,6541	0,66	0,6265	0,6305	0,5894	0,5836	0,5871
0,679	0,6844	0,6684	0,6688	0,5964	0,5905	0,5878
0,6488	0,6509	0,392	0,3973	0,6015	0,6009	0,5803
0,4063	0,4077	0,4347	0,4414	0,5717	0,5986	0,5702

* Valores Normalizados

Tabela II.6b – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Açude Pacajus – Modelo M02SED

Antecedentes						Consequente
Volume do Pacajus em t*	Volume do Pacajus em t-1*	Volume do Pacoti/Riachão em t*	Volume do Pacoti/Riachão em t-1*	Volume do Gavião em t*	Volume do Gavião em t-1*	Retirada do Pacajus*
0,6765	0,6824	0,661	0,663	0,596	0,5924	0,3349
0,623	0,6242	0,5955	0,6011	0,5989	0,5918	0,6647
0,6164	0,6174	0,4231	0,4272	0,5884	0,5928	0,6426
0,6404	0,6402	0,5918	0,5948	0,5757	0,5744	0,3442
0,434	0,4329	0,4324	0,4362	0,5591	0,5894	0,6047
0,6456	0,6343	0,5312	0,5273	0,5666	0,5673	0,3615
0,6765	0,6824	0,661	0,663	0,596	0,5924	0,3349

* Valores Normalizados

Tabela II.6c – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Canal do Trabalhador – Modelo M02SED

Antecedentes						Consequente
Volume do Pacajus em t*	Volume do Pacajus em t-1*	Volume do Pacoti/Riachão em t*	Volume do Pacoti/Riachão em t-1*	Volume do Gavião em t*	Volume do Gavião em t-1*	Retirada do Canal do Trabalhador*
0,4114	0,415	0,4359	0,4412	0,5698	0,6077	0,4416
0,6424	0,6391	0,5927	0,5916	0,576	0,5755	0,3725
0,6008	0,5583	0,4905	0,4727	0,4489	0,4626	0,4071
0,6237	0,6264	0,5474	0,5557	0,6078	0,6012	0,5496
0,6631	0,6712	0,6467	0,6532	0,6032	0,5994	0,5402
0,6789	0,6822	0,6651	0,6616	0,5969	0,5854	0,3504
0,6408	0,644	0,3999	0,4076	0,6036	0,6039	0,5214

* Valores Normalizados

Tabela II.7a – Agrupamentos – Coeficientes de Eficiência – Retirada dos Açúdes Pacoti/Riachão – Modelo M03SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	15.9022	1	0
2	0.6840	0.7606	0.2606
3	-1.6034	0.6235	0.2901
4	-2.5496	0.5648	0.3148
5	-2.9671	0.5044	0.3044
6	-3.6321	0.4986	0.3319
7	-3.5319	0.4617	0.3188
8	-3.7852	0.4482	0.3232
9	-3.8144	0.4300	0.3189

Tabela II.7b – Agrupamentos – Coeficientes de Eficiência – Retirada do Açude Pacajus – Modelo M03SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	27.6024	1	0
2	-2.1871	0.7967	0.2967
3	-6.7676	0.6924	0.3591
4	-11.4819	0.6702	0.4202
5	-12.2265	0.6277	0.4277
6	-12.9115	0.6106	0.4440
7	-13.2516	0.5903	0.4475
8	-13.1377	0.5757	0.4507
9	-13.2525	0.5644	0.4533

Tabela II.7c – Agrupamentos – Coeficientes de Eficiência – Retirada do Canal do Trabalhador – Modelo M03SED

c	Índice de Validade do Agrupamento (Vd)	Coeficiente de Partição Difusa (Pd)	Coeficiente de Partição Difusa Significativa (Pd sig)
1	20.5193	1	0
2	4.1094	0.6996	0.1996
3	-2.0585	0.6284	0.2951
4	-3.5498	0.5573	0.3073
5	-4.5696	0.5077	0.3077
6	-5.1421	0.4868	0.3201
7	-5.5455	0.4691	0.3262
8	-5.7945	0.4503	0.3253
9	-6.2549	0.4512	0.3401

Tabela II.8a – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada dos Açudes Pacoti/Riachão – Modelo M03SED

Antecedentes			Consequente	
Volume Total do Sistema em t*	Volume Total do Sistema em t-1*	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacoti/Riachão em t-1*	Retirada do Pacoti/Riachão*
0,4732	0,4742	0,3074	0,3086	0,4037
0,4281	0,4337	0,3033	0,3055	0,6017
0,6073	0,6184	0,3028	0,3057	0,6027
0,6774	0,6842	0,3060	0,3212	0,5964
0,6728	0,6162	0,3723	0,4203	0,5407
0,5444	0,5515	0,3048	0,3086	0,5896

* Valores Normalizados

Tabela II.8b – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Açude Pacajus – Modelo M03SED

Antecedentes			Consequente	
Volume Total do Sistema em t*	Volume Total do Sistema em t-1*	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacoti/Riachão em t-1*	Retirada do Pacoti/Riachão*
0,6606	0,6648	0,3077	0,3183	0,6619
0,4128	0,4188	0,3025	0,3036	0,6767
0,6698	0,6109	0,3709	0,4179	0,3878
0,5914	0,6016	0,3033	0,3067	0,3176
0,6743	0,6826	0,3048	0,3194	0,3190
0,5561	0,5634	0,3043	0,3055	0,6854
0,4622	0,4656	0,3051	0,3091	0,3302

* Valores Normalizados

Tabela II.8c – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Canal do Trabalhador – Modelo M03SED

Antecedentes			Consequente	
Volume Total do Sistema em t*	Volume Total do Sistema em t-1*	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacoti/Riachão em t-1*	Retirada do Pacoti/Riachão*
0,4546	0,4584	0,3038	0,3061	0,4576
0,4485	0,4470	0,3071	0,3116	0,3301
0,6680	0,6755	0,3057	0,3186	0,4504
0,6774	0,6802	0,3114	0,3284	0,3211
0,6660	0,6758	0,3020	0,3138	0,6010
0,5579	0,5684	0,3015	0,3044	0,6004
0,6748	0,6059	0,3803	0,4315	0,3311
0,5926	0,6020	0,3038	0,3062	0,3185
0,4316	0,4408	0,3015	0,3035	0,5938

* Valores Normalizados

Tabela II.9a – Agrupamentos – Coeficientes de Eficiência – Retirada dos Açudes Pacoti/Riachão – Modelo M04SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	17.5625	1	0
2	2.4048	0.7353	0.2353
3	-0.4613	0.5973	0.2640
4	-1.9305	0.5453	0.2953
5	-2.4648	0.5032	0.3032
6	-2.8672	0.4718	0.3051
7	-2.7528	0.4365	0.2936
8	-2.9791	0.4277	0.3027
9	-2.9450	0.3967	0.2856

Tabela II.9b – Agrupamentos – Coeficientes de Eficiência – Retirada do Açude Pacajus – Modelo M04SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	29.2615	1	0
2	-0.8319	0.7884	0.2884
3	-4.8271	0.6582	0.3248
4	-9.3940	0.6288	0.3788
5	-10.5797	0.5946	0.3946
6	-11.7443	0.5879	0.4212
7	-12.1109	0.5654	0.4226
8	-11.5487	0.5180	0.3930
9	-11.6788	0.5110	0.3999

Tabela II.9c – Agrupamentos – Coeficientes de Eficiência – Retirada do Canal do Trabalhador – Modelo M04SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	22.2787	1	0
2	5.7925	0.6784	0.1784
3	-0.5151	0.6026	0.2693
4	-2.3259	0.5255	0.2755
5	-3.5977	0.4954	0.2954
6	-4.3431	0.4661	0.2995
7	-4.8450	0.4509	0.3080
8	-4.9608	0.4230	0.2980
9	-5.0567	0.3994	0.2883

Tabela II.10a – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada dos Açudes Pacoti/Riachão – Modelo M04SED

Volume Total do Sistema em t*	Antecedentes				Consequentes	
	Volume Total do Sistema em t-1*	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacajus em t-2*	Vazão Afluente ao Pacoti/Riachão em t-1*	Vazão Afluente ao Pacoti/Riachão em t-2*	Retirada do Pacoti/Riachão*
0,6080	0,6187	0,3033	0,3032	0,3062	0,3061	0,6020
0,6744	0,6820	0,3047	0,3085	0,3186	0,3272	0,5990
0,5491	0,5559	0,3052	0,3043	0,3092	0,3078	0,5910
0,5065	0,5023	0,3121	0,3042	0,3145	0,3060	0,4252
0,6837	0,6565	0,3538	0,3701	0,3990	0,4209	0,5577
0,4254	0,4307	0,3036	0,3026	0,3058	0,3041	0,5964

* Valores Normalizados

Tabela II.10b – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Açude Pacajus – Modelo M04SED

Volume Total do Sistema em t*	Antecedentes					Consequentes
	Volume Total do Sistema em t-1*	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacajus em t-2*	Vazão Afluente ao Pacoti/Riachão em t-1*	Vazão Afluente ao Pacoti/Riachão em t-2*	Retirada do Pacajus*
0,6722	0,6810	0,3041	0,3078	0,3179	0,3261	0,3183
0,6561	0,6607	0,3070	0,3125	0,3165	0,3232	0,6625
0,5581	0,5653	0,3040	0,3037	0,3056	0,3049	0,6844
0,6814	0,6475	0,3586	0,3663	0,4043	0,4165	0,3893
0,5928	0,6023	0,3039	0,3020	0,3074	0,3050	0,3184
0,4636	0,4648	0,3070	0,3027	0,3109	0,3052	0,3362
0,4131	0,4189	0,3028	0,3021	0,3039	0,3031	0,6764

* Valores Normalizados

Tabela II.10c – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Canal do Trabalhador – Modelo M04SED

Volume Total do Sistema em t*	Antecedentes					Consequentes
	Volume Total do Sistema em t-1*	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacajus em t-2*	Vazão Afluente ao Pacoti/Riachão em t-1*	Vazão Afluente ao Pacoti/Riachão em t-2*	Retirada do Canal do Trabalhador*
0,5993	0,6076	0,3051	0,3027	0,3084	0,3053	0,3187
0,5600	0,5688	0,3031	0,3034	0,3060	0,3071	0,5560
0,4333	0,4408	0,3025	0,3034	0,3044	0,3050	0,5562
0,6635	0,6699	0,3071	0,3106	0,3202	0,3273	0,4085
0,4387	0,4364	0,3084	0,3030	0,3119	0,3045	0,3573
0,6625	0,6720	0,3028	0,3060	0,3141	0,3209	0,5908
0,6844	0,6572	0,3481	0,3639	0,3917	0,4125	0,3271

* Valores Normalizados

Tabela II.11a – Agrupamentos – Coeficientes de Eficiência – Retirada dos Açudes Pacoti/Riachão – Modelo M05SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	16.3585	1	0
2	4.3079	0.6859	0.1859
3	1.8395	0.5327	0.1994
4	-0.4375	0.4989	0.2489
5	-1.4583	0.4586	0.2586
6	-1.8473	0.4169	0.2502
7	-2.1918	0.3942	0.2513
8	-2.2024	0.3578	0.2328
9	-2.7000	0.3564	0.2453

Tabela II.11b – Agrupamentos – Coeficientes de Eficiência – Retirada do Açude Pacajus – Modelo M05SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	28.0586	1	0
2	-1.3244	0.7934	0.2934
3	-3.6370	0.6213	0.2879
4	-5.9748	0.5635	0.3135
5	-6.4396	0.5092	0.3092
6	-6.8253	0.4845	0.3178
7	-7.4113	0.4679	0.3250
8	-9.4219	0.4808	0.3558
9	-9.2151	0.4455	0.3344

Tabela II.11c – Agrupamentos – Coeficientes de Eficiência – Retirada do Canal do Trabalhador – Modelo M05SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	20.9755	1	0
2	5.5776	0.6780	0.1780
3	0.7434	0.5716	0.2382
4	-0.4048	0.4656	0.2156
5	-2.4018	0.4512	0.2512
6	-2.8907	0.4204	0.2537
7	-3.1938	0.3914	0.2486
8	-3.4316	0.3685	0.2435
9	-3.6165	0.3605	0.2494

Tabela II.12a – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada dos Açudes Pacoti/Riachão – Modelo M05SED

Antecedentes				Consequente
Volume do Açude Pacajus em t*	Volume do s Açudes Pacoti/Riachão em t*	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacoti/Riachão em t-1*	Retirada do Pacoti/Riachão*
0,613	0,5718	0,3029	0,3057	0,5956
0,6735	0,6581	0,3066	0,3203	0,5992
0,6858	0,6483	0,354	0,3955	0,5348
0,6499	0,4052	0,3072	0,3097	0,5758
0,4174	0,4377	0,3015	0,3042	0,5695

* Valores Normalizados

Tabela II.12b – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Açude Pacajus – Modelo M05SED

Antecedentes				Consequente
Volume do Açude Pacajus em t*	Volume do s Açudes Pacoti/Riachão em t*	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacoti/Riachão em t-1*	Retirada do Pacajus*
0,6823	0,6669	0,3055	0,3213	0,3191
0,5995	0,3714	0,3035	0,3038	0,678
0,6265	0,5855	0,3024	0,3053	0,3176
0,4229	0,4595	0,3014	0,3039	0,3539
0,6763	0,439	0,3085	0,3144	0,3265
0,691	0,6578	0,3661	0,4135	0,3923
0,6391	0,6289	0,3073	0,3139	0,6736
0,5782	0,5254	0,3026	0,3043	0,6842

* Valores Normalizados

Tabela II.12c – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Canal do Trabalhador – Modelo M05SED

Antecedentes				Consequente
Volume do Açude Pacajus em t*	Volume do s Açudes Pacoti/Riachão em t*	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacoti/Riachão em t-1*	Retirada do Canal do Trabalhador*
0,6426	0,4107	0,305	0,3061	0,5238
0,6285	0,5917	0,3021	0,3071	0,6061
0,6298	0,5815	0,3053	0,3089	0,3254
0,6886	0,6605	0,3398	0,3773	0,326
0,4268	0,4358	0,3017	0,3042	0,4127
0,6689	0,6494	0,3076	0,3207	0,4632

* Valores Normalizados

Tabela II.13a – Agrupamentos – Coeficientes de Eficiência – Retirada dos Açúdes Pacoti/Riachão – Modelo M06SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	17.6509	1	0
2	5.7083	0.6550	0.1550
3	2.7815	0.5085	0.1752
4	1.3569	0.4387	0.1887
5	-0.7044	0.4405	0.2405
6	-1.1810	0.3954	0.2287
7	-1.3186	0.3543	0.2115
8	-1.3951	0.3274	0.2024
9	-1.5604	0.3130	0.2019

Tabela II.13b – Agrupamentos – Coeficientes de Eficiência – Retirada do Açúde Pacajus – Modelo M06SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	29.3500	1	0
2	-0.2390	0.7865	0.2865
3	-2.3340	0.5924	0.2591
4	-4.8135	0.5413	0.2913
5	-5.9009	0.4994	0.2994
6	-5.7921	0.4567	0.2901
7	-6.7981	0.4532	0.3104
8	-8.6552	0.4624	0.3374
9	-8.4403	0.4317	0.3206

Tabela II.13c – Agrupamentos – Coeficientes de Eficiência – Retirada do Canal do Trabalhador – Modelo M06SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	22.3672	1	0
2	6.8117	0.6621	0.1621
3	2.3466	0.5386	0.2053
4	0.2569	0.4611	0.2111
5	-1.3599	0.4339	0.2339
6	-1.9897	0.3995	0.2328
7	-2.2764	0.3626	0.2198
8	-2.5008	0.3419	0.2169
9	-2.6689	0.3312	0.2200

Tabela II.14a – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada dos Açúdes Pacoti/Riachão – Modelo M06SED

Volume do Açúde Pacajus em t	Antecedentes				Consequente	
	Volume dos Açúdes Pacoti/Riachão em t	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacajus em t-2*	Vazão Afluente ao Pacoti/Riachão em t-1*	Vazão Afluente ao Pacoti/Riachão em t-2*	Retirada do Pacoti/Riachão*
0,4365	0,4324	0,3022	0,302	0,3047	0,3038	0,5695
0,6899	0,6622	0,3507	0,3565	0,3931	0,3987	0,551
0,6522	0,414	0,308	0,3063	0,3107	0,3079	0,5743
0,6158	0,5759	0,3033	0,3029	0,3063	0,3062	0,595
0,6714	0,6542	0,3062	0,3086	0,3193	0,325	0,5958

* Valores Normalizados

Tabela II.14b – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Açude Pacajus – Modelo M06SED

Antecedentes						Consequente
Volume do Açude Pacajus em t	Volume dos Açudes Pacoti/Riachão em t	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacajus em t-2*	Vazão Afluente ao Pacoti/Riachão em t-1*	Vazão Afluente ao Pacoti/Riachão em t-2*	Retirada do Pacajus*
0,5999	0,5607	0,3025	0,3024	0,3045	0,3045	0,6852
0,6922	0,6665	0,3555	0,3598	0,4022	0,407	0,3792
0,3781	0,4091	0,3012	0,3012	0,3033	0,3034	0,6605
0,6632	0,653	0,3115	0,3177	0,3244	0,3317	0,6496
0,6287	0,3798	0,3049	0,3047	0,305	0,3046	0,6731
0,679	0,6625	0,3049	0,308	0,3196	0,3258	0,3184
0,6671	0,4433	0,3088	0,3041	0,3138	0,3094	0,3267
0,6214	0,582	0,3027	0,3018	0,3055	0,3049	0,3182

* Valores Normalizados

Tabela II.14c – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Canal do Trabalhador – Modelo M06SED

Antecedentes						Consequente
Volume do Açude Pacajus em t	Volume dos Açudes Pacoti/Riachão em t	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacajus em t-2*	Vazão Afluente ao Pacoti/Riachão em t-1*	Vazão Afluente ao Pacoti/Riachão em t-2*	Retirada do Canal do Trabalhador*
0,6524	0,6324	0,3037	0,3062	0,3128	0,3185	0,5601
0,6895	0,6615	0,3426	0,3474	0,3819	0,3868	0,3399
0,6409	0,5936	0,3065	0,3043	0,3118	0,3098	0,3342
0,4787	0,4325	0,3034	0,3027	0,306	0,3045	0,4196
0,6379	0,4543	0,3046	0,3056	0,3067	0,3077	0,5518

* Valores Normalizados

Tabela II.15a – Agrupamentos – Coeficientes de Eficiência – Retirada dos Açudes Pacoti/Riachão – Modelo M07SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	35.0845	1	0
2	3.2560	0.7341	0.2341
3	0.5162	0.5241	0.1907
4	-0.8635	0.4406	0.1906
5	-1.5854	0.3655	0.1655
6	-2.1442	0.3351	0.1684
7	-2.3005	0.2924	0.1496
8	-2.4818	0.2739	0.1489
9	-2.7907	0.2617	0.1506

Tabela II.15b – Agrupamentos – Coeficientes de Eficiência – Retirada do Açude Pacajus – Modelo M07SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	46.7846	1	0
2	-7.0629	0.8011	0.3011
3	-8.3877	0.5778	0.2445
4	-8.1458	0.4916	0.2416
5	-8.5948	0.4173	0.2173
6	-9.0418	0.3882	0.2216
7	-8.5353	0.3421	0.1993
8	-8.7177	0.3209	0.1959
9	-8.6062	0.3040	0.1929

Tabela II.15c – Agrupamentos – Coeficientes de Eficiência – Retirada do Canal do Trabalhador – Modelo M07SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	39.7015	1	0
2	2.9566	0.7334	0.2334
3	-0.4659	0.5368	0.2034
4	-2.2119	0.4507	0.2007
5	-2.4759	0.3625	0.1625
6	-2.8764	0.3260	0.1593
7	-3.2463	0.2917	0.1488
8	-3.3891	0.2642	0.1392
9	-3.4977	0.2486	0.1374

Tabela II.16a – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada dos Açudes Pacoti/Riachão – Modelo M07SED

Volume Total do Sistema em t*	Antecedentes			Consequente
	Retirada do Canal do Trabalhador em t-1*	Retirada do Pacajus em t-1*	Retirada do Pacoti/Riachão em t-1*	Retirada do Pacoti/Riachão*
0,6025	0,4511	0,3357	0,5904	0,5851
0,6312	0,3309	0,3431	0,5597	0,5695
0,551	0,5768	0,6649	0,5931	0,5874
0,5221	0,4499	0,6347	0,5713	0,5766

* Valores Normalizados

Tabela II.16b – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Açude Pacajus – Modelo M07SED

Volume Total do Sistema em t*	Antecedentes			Consequente
	Retirada do Canal do Trabalhador em t-1*	Retirada do Pacajus em t-1*	Retirada do Pacoti/Riachão em t-1*	Retirada do Pacoti/Riachão*
0,4803	0,4803	0,6708	0,5783	0,6696
0,6019	0,3936	0,5317	0,5589	0,5402
0,6089	0,5224	0,3227	0,6007	0,3204
0,5893	0,3428	0,3281	0,5862	0,3311
0,5649	0,6023	0,6819	0,599	0,6851
0,6505	0,3301	0,3478	0,5425	0,3504

* Valores Normalizados

Tabela II.16c – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Canal do Trabalhador – Modelo M07SED

Volume Total do Sistema em t*	Antecedentes			Consequente
	Retirada do Canal do Trabalhador em t-1*	Retirada do Pacajus em t-1*	Retirada do Pacoti/Riachão em t-1*	Retirada do Pacoti/Riachão*
0,5248	0,4586	0,6366	0,569	0,4585
0,6237	0,3337	0,3416	0,5599	0,3386
0,5483	0,5827	0,6641	0,5987	0,5824
0,6023	0,4447	0,346	0,5867	0,4407

* Valores Normalizados

Tabela II.17a – Agrupamentos – Coeficientes de Eficiência – Retirada dos Açudes Pacoti/Riachão – Modelo M08SED

c	Índice de Validade do Agrupamento (Vd)	Coeficiente de Partição Difusa (Pd)	Coeficiente de Partição Difusa Significativa (Pd sig)
1	37.2054	1	0
2	5.1263	0.7197	0.2197
3	2.0584	0.4975	0.1642
4	0.7074	0.4108	0.1608
5	-0.6952	0.3543	0.1543
6	-0.9204	0.2990	0.1323
7	-1.3310	0.2728	0.1299
8	-1.3981	0.2401	0.1151
9	-1.4445	0.2161	0.1049

Tabela II.17b – Agrupamentos – Coeficientes de Eficiência – Retirada do Açude Pacajus – Modelo M08SED

c	Índice de Validade do Agrupamento (Vd)	Coeficiente de Partição Difusa (Pd)	Coeficiente de Partição Difusa Significativa (Pd sig)
1	48.9055	1	0
2	-5.2072	0.7911	0.2911
3	-6.6975	0.5552	0.2218
4	-6.4105	0.4662	0.2162
5	-7.8759	0.4126	0.2126
6	-7.9388	0.3633	0.1967
7	-7.5047	0.3259	0.1830
8	-7.4257	0.2930	0.1680
9	-7.7211	0.2855	0.1744

Tabela II.17c – Agrupamentos – Coeficientes de Eficiência – Retirada do Canal do Trabalhador – Modelo M08SED

c	Índice de Validade do Agrupamento (Vd)	Coeficiente de Partição Difusa (Pd)	Coeficiente de Partição Difusa Significativa (Pd sig)
1	41.8225	1	0
2	4.8716	0.7200	0.2200
3	1.2474	0.5100	0.1767
4	-0.3235	0.4176	0.1676
5	-1.6005	0.3539	0.1539
6	-1.6426	0.2942	0.1275
7	-2.2462	0.2738	0.1310
8	-2.4757	0.2467	0.1217
9	-2.5858	0.2296	0.1185

Tabela II.18a – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada dos Açudes Pacoti/Riachão – Modelo M08SED

Volume Total do Sistema em t*	Antecedentes				Consequente	
	Retirada do Canal do Trabalhador em t-1*	Retirada do Pacajus em t-1*	Retirada do Pacoti/Riachão em t-1*	Vazão Afluyente ao Pacajus em t-1*	Vazão Afluyente ao Pacoti/Riachão em t-1*	Retirada do Pacoti/Riachão*
0,6326	0,3405	0,3671	0,5406	0,3299	0,3576	0,5575
0,6063	0,3442	0,3429	0,5804	0,3105	0,3216	0,578
0,6051	0,487	0,3359	0,5947	0,3052	0,3127	0,5897
0,5035	0,465	0,653	0,5782	0,3088	0,3109	0,5776
0,5595	0,5833	0,6712	0,5945	0,3033	0,3062	0,5904

* Valores Normalizados

Tabela II.18b – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Açude Pacajus – Modelo M08SED

Volume Total do Sistema em t*	Antecedentes				Consequente	
	Retirada do Canal do Trabalhador em t-1*	Retirada do Pacajus em t-1*	Retirada do Pacoti/Riachão em t-1*	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacoti/Riachão em t-1*	Retirada do Pacajus*
0,6327	0,3412	0,3658	0,5416	0,328	0,3548	0,3675
0,6143	0,3576	0,4172	0,5404	0,3296	0,352	0,4193
0,5656	0,5948	0,6801	0,5978	0,3023	0,3051	0,6838
0,5986	0,3426	0,3268	0,5893	0,3064	0,3136	0,3287
0,6096	0,5206	0,3243	0,6007	0,3031	0,3099	0,3225
0,4866	0,4746	0,6688	0,579	0,3067	0,3072	0,6677

* Valores Normalizados

Tabela II.18c – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Canal do Trabalhador – Modelo M08SED

Volume Total do Sistema em t*	Antecedentes				Consequente	
	Retirada do Canal do Trabalhador em t-1*	Retirada do Pacajus em t-1*	Retirada do Pacoti/Riachão em t-1*	Vazão Afluente ao Pacajus em t-1*	Vazão Afluente ao Pacoti/Riachão em t-1*	Retirada do Canal do Trabalhador*
0,5999	0,4753	0,3499	0,5926	0,3062	0,3147	0,474
0,6333	0,3443	0,3661	0,5436	0,3283	0,3549	0,3554
0,6012	0,35	0,3415	0,5779	0,3111	0,3218	0,3453
0,5518	0,5919	0,6716	0,6001	0,3022	0,3053	0,5908
0,5128	0,472	0,6543	0,5744	0,3092	0,3104	0,4703

* Valores Normalizados

Tabela II.19a – Agrupamentos – Coeficientes de Eficiência – Retirada dos Açudes Pacoti/Riachão – Modelo M09SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	40.7774	1	0
2	7.3205	0.7072	0.2072
3	4.1439	0.4799	0.1465
4	2.1093	0.3970	0.1470
5	0.7643	0.3357	0.1357
6	-0.0029	0.3041	0.1374
7	-0.3116	0.2617	0.1189
8	-0.4971	0.2317	0.1067
9	-0.6709	0.2143	0.1032

Tabela II.19b – Agrupamentos – Coeficientes de Eficiência – Retirada do Açude Pacajus – Modelo M09SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	52.4775	1	0
2	-2.2438	0.7752	0.2752
3	-3.4377	0.5255	0.1922
4	-4.0165	0.4426	0.1926
5	-5.0222	0.3758	0.1758
6	-5.4692	0.3472	0.1805
7	-5.1025	0.2950	0.1521
8	-5.4170	0.2762	0.1512
9	-4.8332	0.2435	0.1324

Tabela II.19c – Agrupamentos – Coeficientes de Eficiência – Retirada do Canal do Trabalhador – Modelo M09SED

c	Índice de Validade do Agrupamento (Vd)	Coefficiente de Partição Difusa (Pd)	Coefficiente de Partição Difusa Significativa (Pd sig)
1	45.3944	1	0
2	7.2140	0.7083	0.2083
3	3.3671	0.4962	0.1629
4	1.5474	0.3987	0.1487
5	0.3726	0.3300	0.1300
6	-0.3749	0.2953	0.1287
7	-0.7676	0.2551	0.1122
8	-0.9228	0.2314	0.1064
9	-1.1880	0.2096	0.0984

Tabela II.20a – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada dos Açudes Pacoti/Riachão – Modelo M09SED

Antecedentes				Consequente	
Volume do Açude Pacajus em t*	Volume dos Açudes Pacoti/Riachão em t*	Retirada do Canal do Trabalhador em t-1*	Retirada do Pacajus em t-1*	Retirada do Pacoti/Riachão em t-1*	Retirada do Pacoti/Riachão*
0,5824	0,4862	0,4802	0,6258	0,5746	0,5722
0,5839	0,4881	0,4810	0,6260	0,5748	0,5727
0,6565	0,5962	0,4838	0,3343	0,5950	0,5891
0,6259	0,5782	0,3509	0,3420	0,5825	0,5735
0,6057	0,5575	0,5745	0,6667	0,5950	0,5930
0,6779	0,6492	0,3303	0,3493	0,5472	0,5699

* Valores Normalizados

Tabela II.20b – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Açude Pacajus – Modelo M09SED

Antecedentes				Consequente	
Volume do Açude Pacajus em t*	Volume dos Açudes Pacoti/Riachão em t*	Retirada do Canal do Trabalhador em t-1*	Retirada do Pacajus em t-1*	Retirada do Pacoti/Riachão em t-1*	Retirada do Pacajus*
0,6247	0,5691	0,4445	0,6120	0,5704	0,6146
0,6035	0,5509	0,5897	0,6780	0,5983	0,6809
0,6242	0,5731	0,3471	0,3331	0,5833	0,3366
0,6610	0,5945	0,5019	0,3267	0,5969	0,3246
0,6758	0,6441	0,3322	0,3508	0,5468	0,3540
0,5535	0,4366	0,4945	0,6574	0,5774	0,6566

* Valores Normalizados

Tabela II.20c – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Canal do Trabalhador – Modelo M09SED

Antecedentes				Consequente	
Volume do Açude Pacajus em t*	Volume dos Açudes Pacoti/Riachão em t*	Retirada do Canal do Trabalhador em t-1*	Retirada do Pacajus em t-1*	Retirada do Pacoti/Riachão em t-1*	Retirada do Canal do Trabalhador*
0,6297	0,5829	0,3549	0,3398	0,5804	0,3472
0,5680	0,4745	0,4781	0,6268	0,5728	0,4739
0,6012	0,5296	0,4800	0,6249	0,5757	0,4831
0,6074	0,5413	0,5989	0,6704	0,6024	0,5963
0,6746	0,6413	0,3343	0,3517	0,5450	0,3493
0,6530	0,5882	0,4677	0,3474	0,5914	0,4644

* Valores Normalizados

Tabela II.21a – Agrupamentos – Coeficientes de Eficiência – Retirada dos Açúdes Pacoti/Riachão – Modelo M10SED

c	Índice de Validade do Agrupamento (Vd)	Coeficiente de Partição Difusa (Pd)	Coeficiente de Partição Difusa Significativa (Pd sig)
1	9.5203	1	0
2	1.4999	0.7357	0.2357
3	-0.1221	0.6026	0.2693
4	-1.4902	0.5770	0.3270
5	-2.0018	0.5309	0.3309
6	-2.0365	0.4905	0.3238
7	-2.0511	0.4631	0.3202
8	-2.2626	0.4505	0.3255
9	-2.3669	0.4460	0.3349

Tabela II.21b – Agrupamentos – Coeficientes de Eficiência – Retirada do Açúde Pacajus – Modelo M10SED

c	Índice de Validade do Agrupamento (Vd)	Coeficiente de Partição Difusa (Pd)	Coeficiente de Partição Difusa Significativa (Pd sig)
1	21.2204	1	0
2	-6.9391	0.8517	0.3517
3	-8.6504	0.7202	0.3868
4	-10.8803	0.6864	0.4364
5	-11.1677	0.6454	0.4454
6	-11.5639	0.6352	0.4686
7	-11.4818	0.6087	0.4658
8	-11.5091	0.5921	0.4671
9	-11.3004	0.5792	0.4681

Tabela II.21c – Agrupamentos – Coeficientes de Eficiência – Retirada do Canal do Trabalhador – Modelo M10SED

c	Índice de Validade do Agrupamento (Vd)	Coeficiente de Partição Difusa (Pd)	Coeficiente de Partição Difusa Significativa (Pd sig)
1	14.1373	1	0
2	0.8584	0.7431	0.2431
3	-2.2961	0.6506	0.3172
4	-3.4329	0.5792	0.3292
5	-3.9954	0.5341	0.3341
6	-4.5790	0.5138	0.3472
7	-4.8616	0.5095	0.3667
8	-5.0472	0.5023	0.3773
9	-4.9087	0.4744	0.3633

Tabela II.22a – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada dos Açúdes Pacoti/Riachão – Modelo M10SED

Antecedentes		Conseqüente
Volume Total do Sistema em t*	Vazão Afluente Total em t-1*	Retirada do Pacoti/Riachão
0,4846	0,3086	0,3955
0,6675	0,3448	0,5263
0,5794	0,3054	0,6043
0,4374	0,3044	0,602
0,6657	0,3121	0,6111

* Valores Normalizados

Tabela II.22b – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Açude Pacajus – Modelo M10SED

Antecedentes		Conseqüente
Volume Total do Sistema em t*	Vazão Afluente Total em t-1*	Retirada do Pacajus
0,6681	0,3391	0,5116
0,5971	0,3069	0,6871
0,5967	0,3069	0,3162
0,6775	0,3185	0,3208
0,426	0,3031	0,6792
0,4632	0,3074	0,3268

* Valores Normalizados

Tabela II.22c – Agrupamentos – Protótipos para orientação da definição de regras heurísticas – Retirada do Canal do Trabalhador – Modelo M10SED

Antecedentes		Conseqüente
Volume Total do Sistema em t*	Vazão Afluente Total em t-1*	Retirada do Canal do Trabalhadores
0,6609	0,313	0,4378
0,6829	0,3456	0,3161
0,5986	0,3075	0,315
0,4643	0,3051	0,4647
0,4361	0,302	0,594
0,45	0,31	0,3274
0,5708	0,3022	0,6404
0,6577	0,3058	0,5748

* Valores Normalizados

ANEXO III – MODELAGEM POR REDES NEURAIS ARTIFICIAIS – VALORES DO INDICADOR DE ERRO

Tabela III.1 – Indicador de Desempenho – Modelo M01RNA –Valores Médios

		Erro Percentual Médio Absoluto (EPMA) – Valores Médios	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	20,72	19,71	19,32
		Conjunto de Validação	21,62	21,32	21,49
	6	Conjunto de Treinamento	20,29	18,24	19,39
		Conjunto de Validação	21,35	21,87	21,77
	9	Conjunto de Treinamento	19,44	18,90	19,35
		Conjunto de Validação	21,50	21,96	21,97
	12	Conjunto de Treinamento	19,05	19,19	18,96
		Conjunto de Validação	20,72	19,71	19,32

Tabela III.2 – Indicador de Desempenho – Modelo M01RNA –Valores Individualizados

		Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açúdes Pacoti/Riachão	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	11,40	10,88	10,84
		Conjunto de Validação	12,85	12,77	12,87
	6	Conjunto de Treinamento	11,09	11,18	11,08
		Conjunto de Validação	13,35	14,31	13,30
	9	Conjunto de Treinamento	10,88	10,53	10,79
		Conjunto de Validação	13,35	13,61	13,07
	12	Conjunto de Treinamento	10,66	10,54	10,41
		Conjunto de Validação	13,38	13,45	13,25

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Açúde Pacajus	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	28,36	26,31	25,42
		Conjunto de Validação	26,48	26,47	26,29
	6	Conjunto de Treinamento	27,48	23,14	25,47
		Conjunto de Validação	25,18	26,15	25,87
	9	Conjunto de Treinamento	25,65	24,81	25,56
		Conjunto de Validação	25,78	26,29	27,01
	12	Conjunto de Treinamento	25,24	25,86	25,49
		Conjunto de Validação	26,07	25,60	25,56

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	22,38	21,95	21,70
		Conjunto de Validação	25,53	24,71	25,31
	6	Conjunto de Treinamento	22,29	20,40	21,63
		Conjunto de Validação	25,51	25,15	26,13
	9	Conjunto de Treinamento	21,80	21,35	21,70
		Conjunto de Validação	25,38	25,98	25,83
	12	Conjunto de Treinamento	21,26	21,17	20,98
		Conjunto de Validação	26,00	25,41	25,10

Tabela III.3 – Indicador de Desempenho – Modelo M02RNA –Valores Médios

Erro Percentual Médio Absoluto (EPMA) – Valores Médios		Número de Nós - Camada Oculta 1			
		7	10	13	
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	17,65	17,82	17,95
		Conjunto de Validação	19,77	20,11	21,02
6	Conjunto de Treinamento	17,44	17,68	17,69	
	Conjunto de Validação	20,23	20,22	20,45	
9	Conjunto de Treinamento	17,71	15,81	17,43	
	Conjunto de Validação	20,16	20,67	20,27	
12	Conjunto de Treinamento	16,05	17,53	17,74	
	Conjunto de Validação	21,43	20,93	20,82	

Tabela III.4 – Indicador de Desempenho – Modelo M02RNA –Valores Individualizados

Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açúdes Pacoti/Riachão		Número de Nós - Camada Oculta 1			
		7	10	13	
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	10,68	10,61	10,29
		Conjunto de Validação	12,49	12,90	12,48
6	Conjunto de Treinamento	10,89	10,83	10,84	
	Conjunto de Validação	12,18	12,41	12,14	
9	Conjunto de Treinamento	10,69	9,72	10,62	
	Conjunto de Validação	12,11	13,11	12,40	
12	Conjunto de Treinamento	9,60	10,16	9,58	
	Conjunto de Validação	13,10	12,20	12,69	

Erro Percentual Médio Absoluto (EPMA) – Retirada do Açúde Pacajus		Número de Nós - Camada Oculta 1			
		7	10	13	
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	22,26	22,68	23,44
		Conjunto de Validação	23,26	23,59	25,86
6	Conjunto de Treinamento	21,69	21,83	22,52	
	Conjunto de Validação	24,27	24,06	24,78	
9	Conjunto de Treinamento	22,00	18,97	22,17	
	Conjunto de Validação	24,97	24,83	24,59	
12	Conjunto de Treinamento	19,34	22,60	22,50	
	Conjunto de Validação	25,33	24,73	24,76	

Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador		Número de Nós - Camada Oculta 1			
		7	10	13	
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	20,02	20,18	20,13
		Conjunto de Validação	23,55	23,84	24,72
6	Conjunto de Treinamento	19,74	20,37	19,71	
	Conjunto de Validação	24,24	24,19	24,43	
9	Conjunto de Treinamento	20,45	18,73	19,49	
	Conjunto de Validação	23,40	24,08	23,83	
12	Conjunto de Treinamento	19,22	19,82	21,14	
	Conjunto de Validação	25,87	25,85	25,01	

Tabela III.4 – Indicador de Desempenho – Modelo M03RNA –Valores Médios

Erro Percentual Médio Absoluto (EPMA) – Valores Médios		Número de Nós - Camada Oculta 1		
		7	10	13
0	Conjunto de Treinamento	18,21	17,55	18,72
	Conjunto de Validação	20,77	21,20	22,15
6	Conjunto de Treinamento	18,96	19,85	19,35
	Conjunto de Validação	21,90	21,14	21,62
9	Conjunto de Treinamento	18,61	19,22	18,44
	Conjunto de Validação	21,88	20,82	21,57
12	Conjunto de Treinamento	18,28	18,57	19,20
	Conjunto de Validação	22,38	21,74	21,40

Tabela III.5 – Indicador de Desempenho – Modelo M03RNA –Valores Individualizados

Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açúdes Pacoti/Riachão		Número de Nós - Camada Oculta 1		
		7	10	13
0	Conjunto de Treinamento	10,96	10,78	10,37
	Conjunto de Validação	12,13	11,72	12,35
6	Conjunto de Treinamento	10,92	10,45	10,93
	Conjunto de Validação	11,78	12,25	11,76
9	Conjunto de Treinamento	10,48	10,40	10,38
	Conjunto de Validação	12,18	11,68	12,37
12	Conjunto de Treinamento	10,48	10,28	10,35
	Conjunto de Validação	12,25	12,30	12,23

Erro Percentual Médio Absoluto (EPMA) – Retirada do Açúde Pacajus		Número de Nós - Camada Oculta 1		
		7	10	13
0	Conjunto de Treinamento	24,04	22,61	25,77
	Conjunto de Validação	27,75	28,68	29,91
6	Conjunto de Treinamento	25,69	28,31	26,59
	Conjunto de Validação	29,71	28,13	29,42
9	Conjunto de Treinamento	25,23	26,95	25,40
	Conjunto de Validação	29,89	27,68	29,03
12	Conjunto de Treinamento	24,74	25,35	26,85
	Conjunto de Validação	31,22	29,10	28,55

Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador		Número de Nós - Camada Oculta 1		
		7	10	13
0	Conjunto de Treinamento	19,63	19,27	20,01
	Conjunto de Validação	22,42	23,21	24,20
6	Conjunto de Treinamento	20,26	20,79	20,51
	Conjunto de Validação	24,20	23,05	23,68
9	Conjunto de Treinamento	20,11	20,30	19,53
	Conjunto de Validação	23,56	23,10	23,31
12	Conjunto de Treinamento	19,61	20,08	20,41
	Conjunto de Validação	23,65	23,82	23,41

Tabela III.6 – Indicador de Desempenho – Modelo M04RNA –Valores Médios

Erro Percentual Médio Absoluto (EPMA) – Valores Médios		Número de Nós - Camada Oculta 1		
		7	10	13
0	Conjunto de Treinamento	28,74	29,10	34,09
	Conjunto de Validação	33,46	34,99	35,55
6	Conjunto de Treinamento	29,30	28,42	29,18
	Conjunto de Validação	34,73	35,19	35,97
9	Conjunto de Treinamento	28,90	29,03	29,06
	Conjunto de Validação	34,42	35,32	36,43
12	Conjunto de Treinamento	29,31	28,81	27,76
	Conjunto de Validação	34,29	35,43	35,29

Tabela III.7 – Indicador de Desempenho – Modelo M04RNA –Valores Individualizados

Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açúdes Pacoti/Riachão		Número de Nós - Camada Oculta 1		
		7	10	13
0	Conjunto de Treinamento	15,55	15,43	15,02
	Conjunto de Validação	16,02	15,73	15,76
6	Conjunto de Treinamento	16,07	15,53	15,04
	Conjunto de Validação	15,75	15,65	16,46
9	Conjunto de Treinamento	15,65	15,24	14,97
	Conjunto de Validação	15,52	16,34	16,38
12	Conjunto de Treinamento	15,49	15,35	14,59
	Conjunto de Validação	15,60	16,60	16,85

Erro Percentual Médio Absoluto (EPMA) – Retirada do Açúde Pacajus		Número de Nós - Camada Oculta 1		
		7	10	13
0	Conjunto de Treinamento	33,32	33,30	44,64
	Conjunto de Validação	43,10	47,14	44,99
6	Conjunto de Treinamento	32,62	31,81	33,49
	Conjunto de Validação	44,31	46,84	47,26
9	Conjunto de Treinamento	32,70	33,72	34,40
	Conjunto de Validação	44,65	47,23	48,75
12	Conjunto de Treinamento	33,38	32,54	30,72
	Conjunto de Validação	45,23	46,65	46,79

Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador		Número de Nós - Camada Oculta 1		
		7	10	13
0	Conjunto de Treinamento	37,35	38,56	42,60
	Conjunto de Validação	41,28	42,11	45,91
6	Conjunto de Treinamento	39,19	37,91	39,01
	Conjunto de Validação	44,12	43,09	44,19
9	Conjunto de Treinamento	38,35	38,12	37,80
	Conjunto de Validação	43,08	42,38	44,16
12	Conjunto de Treinamento	39,07	38,55	37,98
	Conjunto de Validação	42,03	43,04	42,21

Tabela III.8 – Indicador de Desempenho – Modelo M05RNA –Valores Médios

		Erro Percentual Médio Absoluto (EPMA) – Valores Médios	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	18,52	18,88	18,80
		Conjunto de Validação	20,56	20,67	20,48
	6	Conjunto de Treinamento	18,66	17,94	17,33
		Conjunto de Validação	20,26	20,51	21,54
	9	Conjunto de Treinamento	17,77	16,56	16,35
		Conjunto de Validação	21,37	23,22	22,41
12	Conjunto de Treinamento	17,20	17,25	17,20	
	Conjunto de Validação	20,96	20,99	20,93	

Tabela III.9 – Indicador de Desempenho – Modelo M05RNA –Valores Individualizados

		Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açudes Pacoti/Riachão	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	10,22	10,52	10,16
		Conjunto de Validação	11,90	12,26	11,92
	6	Conjunto de Treinamento	10,29	10,18	10,20
		Conjunto de Validação	11,79	11,88	11,84
	9	Conjunto de Treinamento	10,73	10,22	9,61
		Conjunto de Validação	11,74	11,56	12,18
12	Conjunto de Treinamento	9,95	10,07	10,25	
	Conjunto de Validação	12,02	12,11	11,70	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Açude Pacajus	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	24,62	25,79	26,25
		Conjunto de Validação	26,31	25,73	25,36
	6	Conjunto de Treinamento	25,41	24,28	22,44
		Conjunto de Validação	24,82	25,69	27,92
	9	Conjunto de Treinamento	23,26	20,90	21,38
		Conjunto de Validação	28,61	31,41	28,44
12	Conjunto de Treinamento	22,93	22,48	22,09	
	Conjunto de Validação	27,15	26,19	26,99	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	20,73	20,34	19,97
		Conjunto de Validação	23,49	24,02	24,17
	6	Conjunto de Treinamento	20,29	19,35	19,35
		Conjunto de Validação	24,16	23,96	24,86
	9	Conjunto de Treinamento	19,33	18,56	18,06
		Conjunto de Validação	23,76	26,70	26,61
12	Conjunto de Treinamento	18,72	19,20	19,25	
	Conjunto de Validação	23,72	24,67	24,10	

Tabela III.10 – Indicador de Desempenho – Modelo M06RNA –Valores Médios

		Erro Percentual Médio Absoluto (EPMA) – Valores Médios	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	28,70	28,97	28,43
		Conjunto de Validação	35,52	36,67	37,04
	6	Conjunto de Treinamento	28,54	28,77	28,77
		Conjunto de Validação	36,22	36,62	36,50
	9	Conjunto de Treinamento	26,56	28,52	28,95
		Conjunto de Validação	39,13	38,35	36,29
12	Conjunto de Treinamento	28,49	28,49	28,60	
	Conjunto de Validação	36,35	36,35	36,74	

Tabela III.11 – Indicador de Desempenho – Modelo M06RNA –Valores Individualizados

		Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açudes Pacoti/Riachão	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	15,02	15,30	14,63
		Conjunto de Validação	15,79	15,60	15,00
	6	Conjunto de Treinamento	14,53	14,78	14,62
		Conjunto de Validação	14,92	15,57	16,11
	9	Conjunto de Treinamento	14,88	14,19	14,47
		Conjunto de Validação	14,85	15,34	15,26
12	Conjunto de Treinamento	14,60	14,60	14,24	
	Conjunto de Validação	15,49	15,49	16,07	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Açude Pacajus	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	33,85	33,81	33,94
		Conjunto de Validação	45,98	46,73	47,35
	6	Conjunto de Treinamento	34,27	34,15	35,46
		Conjunto de Validação	44,43	44,69	45,79
	9	Conjunto de Treinamento	29,38	34,67	35,27
		Conjunto de Validação	53,45	50,69	46,02
12	Conjunto de Treinamento	34,64	34,64	34,59	
	Conjunto de Validação	45,30	45,30	46,04	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	37,24	37,81	36,71
		Conjunto de Validação	44,81	47,67	48,76
	6	Conjunto de Treinamento	36,82	37,37	36,23
		Conjunto de Validação	49,32	49,59	47,61
	9	Conjunto de Treinamento	35,41	36,70	37,10
		Conjunto de Validação	49,08	49,04	47,60
12	Conjunto de Treinamento	36,24	36,24	36,97	
	Conjunto de Validação	48,27	48,27	48,13	

Tabela III.12 – Indicador de Desempenho – Modelo M07RNA –Valores Médios

		Erro Percentual Médio Absoluto (EPMA) – Valores Médios	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	26,10	25,22	24,27
		Conjunto de Validação	31,38	31,16	27,79
	6	Conjunto de Treinamento	22,47	22,13	21,42
		Conjunto de Validação	29,42	32,10	32,76
	9	Conjunto de Treinamento	22,44	21,59	19,24
		Conjunto de Validação	29,81	32,18	32,24
	12	Conjunto de Treinamento	22,67	19,52	20,44
		Conjunto de Validação	32,01	33,18	34,45

Tabela III.13 – Indicador de Desempenho – Modelo M07RNA –Valores Individualizados

		Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açúdes Pacoti/Riachão	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	14,17	14,16	14,11
		Conjunto de Validação	15,53	14,93	14,97
	6	Conjunto de Treinamento	14,37	14,10	13,63
		Conjunto de Validação	15,92	15,58	15,61
	9	Conjunto de Treinamento	14,51	13,89	12,97
		Conjunto de Validação	16,09	15,89	16,00
	12	Conjunto de Treinamento	14,09	13,28	12,23
		Conjunto de Validação	15,43	17,20	18,01

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Açúde Pacajus	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	26,09	24,42	24,17
		Conjunto de Validação	35,16	35,59	28,33
	6	Conjunto de Treinamento	21,12	20,15	18,96
		Conjunto de Validação	31,54	36,94	38,45
	9	Conjunto de Treinamento	20,00	18,85	14,86
		Conjunto de Validação	31,67	37,05	38,53
	12	Conjunto de Treinamento	20,62	17,53	19,06
		Conjunto de Validação	36,55	37,08	38,72

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	38,04	37,08	34,54
		Conjunto de Validação	43,44	42,96	40,06
	6	Conjunto de Treinamento	31,93	32,14	31,67
		Conjunto de Validação	40,80	43,79	44,22
	9	Conjunto de Treinamento	32,82	32,02	29,88
		Conjunto de Validação	41,65	43,61	42,20
	12	Conjunto de Treinamento	33,28	27,74	30,04
		Conjunto de Validação	44,04	45,26	46,61

Tabela III.14 – Indicador de Desempenho – Modelo M08RNA –Valores Médios

		Erro Percentual Médio Absoluto (EPMA) – Valores Médios	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	14,10	15,48	13,75
		Conjunto de Validação	15,38	14,94	14,75
	6	Conjunto de Treinamento	15,23	13,88	14,17
		Conjunto de Validação	15,76	14,88	15,30
	9	Conjunto de Treinamento	13,75	13,77	13,83
		Conjunto de Validação	15,02	14,90	14,81
12	Conjunto de Treinamento	13,81	13,60	13,03	
	Conjunto de Validação	15,01	14,60	14,88	

Tabela III.15 – Indicador de Desempenho – Modelo M08RNA –Valores Individualizados

		Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açudes Pacoti/Riachão	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	10,92	11,14,7	11,17
		Conjunto de Validação	12,32	12,07	12,10
	6	Conjunto de Treinamento	11,34	10,97	12,03
		Conjunto de Validação	12,04	11,59	12,76
	9	Conjunto de Treinamento	10,94	10,91	10,89
		Conjunto de Validação	11,73	11,85	11,93
12	Conjunto de Treinamento	10,94	10,94	10,30	
	Conjunto de Validação	12,26	12,16	11,76	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Açude Pacajus	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	13,36	13,23	12,48
		Conjunto de Validação	14,38	13,92	13,23
	6	Conjunto de Treinamento	15,85	12,75	12,66
		Conjunto de Validação	15,62	13,60	13,66
	9	Conjunto de Treinamento	12,51	12,78	12,87
		Conjunto de Validação	13,49	13,83	13,61
12	Conjunto de Treinamento	13,46	12,46	11,99	
	Conjunto de Validação	14,42	13,30	14,03	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	18,01	17,74	17,59
		Conjunto de Validação	19,44	18,82	18,91
	6	Conjunto de Treinamento	18,50	17,92	17,82
		Conjunto de Validação	19,62	19,44	19,48
	9	Conjunto de Treinamento	17,81	17,63	17,72
		Conjunto de Validação	19,84	19,03	18,88
12	Conjunto de Treinamento	17,03	17,41	16,80	
	Conjunto de Validação	18,34	18,35	18,86	

Tabela III.16 – Indicador de Desempenho – Modelo M09RNA –Valores Médios

		Erro Percentual Médio Absoluto (EPMA) – Valores Médios	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	13,32	12,97	12,84
		Conjunto de Validação	14,64	14,63	14,60
	6	Conjunto de Treinamento	12,58	12,13	11,82
		Conjunto de Validação	14,84	15,54	15,38
	9	Conjunto de Treinamento	11,97	11,96	11,30
		Conjunto de Validação	15,05	15,32	16,52
	12	Conjunto de Treinamento	11,85	11,29	11,10
		Conjunto de Validação	15,03	15,94	16,61

Tabela III.17 – Indicador de Desempenho – Modelo M09RNA –Valores Individualizados

		Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açúdes Pacoti/Riachão	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	10,42	10,00	9,78
		Conjunto de Validação	11,66	11,90	11,99
	6	Conjunto de Treinamento	9,59	8,96	8,71
		Conjunto de Validação	11,99	12,58	12,51
	9	Conjunto de Treinamento	9,06	8,76	8,25
		Conjunto de Validação	12,04	12,73	13,75
	12	Conjunto de Treinamento	8,91	8,59	8,58
		Conjunto de Validação	12,35	12,76	13,24

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Açúde Pacajus	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,33	12,22	12,15
		Conjunto de Validação	13,68	13,72	13,57
	6	Conjunto de Treinamento	12,04	11,68	11,41
		Conjunto de Validação	13,34	13,98	14,55
	9	Conjunto de Treinamento	11,30	11,61	11,00
		Conjunto de Validação	14,09	14,49	14,78
	12	Conjunto de Treinamento	11,13	10,75	10,44
		Conjunto de Validação	13,83	14,39	15,24

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	17,19	16,68	16,58
		Conjunto de Validação	18,58	18,25	18,24
	6	Conjunto de Treinamento	16,11	15,74	15,35
		Conjunto de Validação	19,17	20,07	19,09
	9	Conjunto de Treinamento	15,56	15,51	14,65
		Conjunto de Validação	19,01	18,74	21,01
	12	Conjunto de Treinamento	15,52	14,51	14,28
		Conjunto de Validação	18,91	20,67	21,36

Tabela III.18 – Indicador de Desempenho – Modelo M01sRNA –Valores Médios

		Erro Percentual Médio Absoluto (EPMA) – Valores Médios	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,69	12,33	12,09
		Conjunto de Validação	14,65	14,91	14,90
	6	Conjunto de Treinamento	12,23	11,93	11,51
		Conjunto de Validação	14,75	15,17	15,53
	9	Conjunto de Treinamento	11,95	11,29	10,87
		Conjunto de Validação	15,08	15,82	16,29
12	Conjunto de Treinamento	11,27	10,77	10,05	
	Conjunto de Validação	15,92	16,33	17,67	

Tabela III.19 – Indicador de Desempenho – Modelo M01sRNA –Valores Individualizados

		Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açudes Pacoti/Riachão	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	9,97	9,70	9,55
		Conjunto de Validação	11,32	11,47	11,39
	6	Conjunto de Treinamento	9,45	9,50	9,37
		Conjunto de Validação	11,58	11,24	11,91
	9	Conjunto de Treinamento	9,56	9,12	8,82
		Conjunto de Validação	11,61	11,94	12,05
12	Conjunto de Treinamento	8,83	8,46	7,93	
	Conjunto de Validação	12,43	12,81	13,59	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Açude Pacajus	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,48	12,03	11,84
		Conjunto de Validação	13,76	14,12	13,94
	6	Conjunto de Treinamento	12,24	12,03	11,56
		Conjunto de Validação	13,74	14,27	13,96
	9	Conjunto de Treinamento	11,97	11,20	11,00
		Conjunto de Validação	13,78	14,71	15,34
12	Conjunto de Treinamento	11,10	10,62	9,81	
	Conjunto de Validação	14,86	14,85	16,20	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	15,63	15,24	14,88
		Conjunto de Validação	18,87	19,15	19,37
	6	Conjunto de Treinamento	15,01	14,28	13,60
		Conjunto de Validação	18,94	19,99	20,73
	9	Conjunto de Treinamento	14,31	13,56	12,79
		Conjunto de Validação	19,84	20,81	21,46
12	Conjunto de Treinamento	13,89	13,22	12,41	
	Conjunto de Validação	20,47	21,35	23,23	

Tabela III.20 – Indicador de Desempenho – Modelo M02sRNA –Valores Médios

		Erro Percentual Médio Absoluto (EPMA) – Valores Médios	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,75	12,65	12,06
		Conjunto de Validação	14,54	14,70	15,06
	6	Conjunto de Treinamento	12,09	11,67	11,41
		Conjunto de Validação	14,88	15,24	15,80
	9	Conjunto de Treinamento	11,85	11,25	10,73
		Conjunto de Validação	15,10	16,03	16,28
	12	Conjunto de Treinamento	11,46	10,61	10,29
		Conjunto de Validação	15,80	16,40	17,26

Tabela III.21 – Indicador de Desempenho – Modelo M02sRNA –Valores Individualizados

		Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açúdes Pacoti/Riachão	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	9,85	9,69	9,56
		Conjunto de Validação	11,33	11,43	11,50
	6	Conjunto de Treinamento	9,93	9,47	9,18
		Conjunto de Validação	11,29	11,65	12,08
	9	Conjunto de Treinamento	9,61	9,12	8,70
		Conjunto de Validação	11,73	12,60	12,48
	12	Conjunto de Treinamento	9,13	8,72	8,52
		Conjunto de Validação	12,02	12,53	13,17

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Açúde Pacajus	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,60	12,55	11,83
		Conjunto de Validação	13,58	13,87	14,13
	6	Conjunto de Treinamento	11,77	11,59	11,71
		Conjunto de Validação	13,93	14,06	14,33
	9	Conjunto de Treinamento	11,56	11,26	10,75
		Conjunto de Validação	14,40	14,33	15,09
	12	Conjunto de Treinamento	11,76	10,74	10,57
		Conjunto de Validação	14,20	14,90	15,19

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	15,79	15,69	14,78
		Conjunto de Validação	18,72	18,80	19,54
	6	Conjunto de Treinamento	14,58	13,95	13,34
		Conjunto de Validação	19,42	20,01	20,99
	9	Conjunto de Treinamento	14,38	13,37	12,74
		Conjunto de Validação	19,16	21,16	21,26
	12	Conjunto de Treinamento	13,49	12,37	11,79
		Conjunto de Validação	21,17	21,76	23,43

Tabela III.22 – Indicador de Desempenho – Modelo M03sRNA –Valores Médios

		Erro Percentual Médio Absoluto (EPMA) – Valores Médios	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,49	12,09	11,62
		Conjunto de Validação	14,46	14,86	15,22
	6	Conjunto de Treinamento	11,66	11,45	10,93
		Conjunto de Validação	15,19	15,06	15,75
	9	Conjunto de Treinamento	11,05	10,81	10,44
		Conjunto de Validação	15,78	15,85	16,77
12	Conjunto de Treinamento	11,14	10,30	10,35	
	Conjunto de Validação	15,24	16,79	16,84	

Tabela III.23 – Indicador de Desempenho – Modelo M03sRNA –Valores Individualizados

		Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açudes Pacoti/Riachão	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	9,12	8,89	8,82
		Conjunto de Validação	10,99	11,05	11,23
	6	Conjunto de Treinamento	8,72	8,57	8,24
		Conjunto de Validação	11,76	11,62	11,72
	9	Conjunto de Treinamento	8,20	8,39	7,68
		Conjunto de Validação	12,26	11,75	12,84
12	Conjunto de Treinamento	8,35	8,11	7,46	
	Conjunto de Validação	11,54	12,48	12,88	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Açude Pacajus	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,18	12,15	11,77
		Conjunto de Validação	13,93	14,52	14,32
	6	Conjunto de Treinamento	11,55	11,83	11,15
		Conjunto de Validação	14,18	14,72	14,65
	9	Conjunto de Treinamento	11,09	10,99	10,66
		Conjunto de Validação	15,05	14,62	15,58
12	Conjunto de Treinamento	10,96	10,45	10,71	
	Conjunto de Validação	14,58	15,40	15,58	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	16,16	15,25	14,29
		Conjunto de Validação	18,45	19,00	20,11
	6	Conjunto de Treinamento	14,71	13,97	13,40
		Conjunto de Validação	19,62	18,86	20,87
	9	Conjunto de Treinamento	13,85	13,06	12,98
		Conjunto de Validação	20,02	21,19	21,88
12	Conjunto de Treinamento	14,11	12,32	12,88	
	Conjunto de Validação	19,60	22,50	22,05	

Tabela III.24 – Indicador de Desempenho – Modelo M04sRNA –Valores Médios

		Erro Percentual Médio Absoluto (EPMA) – Valores Médios	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,59	12,00	11,77
		Conjunto de Validação	14,35	14,77	15,02
	6	Conjunto de Treinamento	12,04	11,41	10,94
		Conjunto de Validação	14,67	15,30	16,21
	9	Conjunto de Treinamento	11,43	10,81	10,44
		Conjunto de Validação	15,53	15,83	16,57
12	Conjunto de Treinamento	11,02	10,78	9,65	
	Conjunto de Validação	15,92	16,19	18,38	

Tabela III.25 – Indicador de Desempenho – Modelo M04sRNA –Valores Individualizados

		Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açúdes Pacoti/Riachão	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	9,23	8,91	8,81
		Conjunto de Validação	11,11	11,12	11,40
	6	Conjunto de Treinamento	8,93	8,52	8,00
		Conjunto de Validação	11,21	11,61	12,24
	9	Conjunto de Treinamento	8,26	8,22	7,66
		Conjunto de Validação	11,76	12,16	13,39
12	Conjunto de Treinamento	8,09	7,93	6,93	
	Conjunto de Validação	12,52	12,52	13,98	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Açúde Pacajus	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,53	12,10	11,79
		Conjunto de Validação	13,25	14,30	14,45
	6	Conjunto de Treinamento	12,19	11,67	11,38
		Conjunto de Validação	13,67	13,89	15,06
	9	Conjunto de Treinamento	12,13	11,14	11,03
		Conjunto de Validação	13,42	14,35	14,60
12	Conjunto de Treinamento	11,14	11,53	10,24	
	Conjunto de Validação	14,64	14,26	15,93	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	16,00	15,00	14,70
		Conjunto de Validação	18,69	18,89	19,22
	6	Conjunto de Treinamento	15,01	14,04	13,44
		Conjunto de Validação	19,14	20,40	21,32
	9	Conjunto de Treinamento	13,91	13,08	12,63
		Conjunto de Validação	21,42	20,97	21,71
12	Conjunto de Treinamento	13,82	12,89	11,79	
	Conjunto de Validação	20,59	21,79	25,23	

Tabela III.26 – Indicador de Desempenho – Modelo M01qRNA –Valores Médios

		Erro Percentual Médio Absoluto (EPMA) – Valores Médios	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,49	12,22	11,77
		Conjunto de Validação	15,05	15,32	15,85
	6	Conjunto de Treinamento	11,70	11,11	10,64
		Conjunto de Validação	15,43	16,54	17,03
	9	Conjunto de Treinamento	11,29	10,70	10,23
		Conjunto de Validação	15,71	16,90	17,50
12	Conjunto de Treinamento	10,61	10,37	9,81	
	Conjunto de Validação	16,36	17,21	18,03	

Tabela III.27 – Indicador de Desempenho – Modelo M01qRNA –Valores Individualizados

		Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açudes Pacoti/Riachão	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	8,86	8,86	8,54
		Conjunto de Validação	11,50	11,65	11,84
	6	Conjunto de Treinamento	8,77	8,30	8,43
		Conjunto de Validação	12,00	12,01	12,00
	9	Conjunto de Treinamento	8,27	8,17	7,88
		Conjunto de Validação	12,56	12,56	12,06
12	Conjunto de Treinamento	8,05	7,83	7,82	
	Conjunto de Validação	12,78	12,09	12,39	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Açude Pacajus	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,59	12,20	11,69
		Conjunto de Validação	13,87	13,98	14,70
	6	Conjunto de Treinamento	11,69	11,24	10,76
		Conjunto de Validação	14,64	14,79	14,98
	9	Conjunto de Treinamento	11,37	10,53	10,36
		Conjunto de Validação	14,30	15,39	16,82
12	Conjunto de Treinamento	10,43	10,25	9,70	
	Conjunto de Validação	15,64	16,34	16,46	

		Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador	Número de Nós - Camada Oculta 1		
			7	10	13
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	16,02	15,59	15,07
		Conjunto de Validação	19,79	20,32	21,00
	6	Conjunto de Treinamento	14,63	13,81	12,74
		Conjunto de Validação	19,63	22,83	24,10
	9	Conjunto de Treinamento	14,23	13,39	12,45
		Conjunto de Validação	20,27	22,76	23,63
12	Conjunto de Treinamento	13,35	13,03	11,90	
	Conjunto de Validação	20,65	23,20	25,25	

Tabela III.28 – Indicador de Desempenho – Modelo M02qRNA –Valores Médios

Erro Percentual Médio Absoluto (EPMA) – Valores Médios		Número de Nós - Camada Oculta 1			
		7	10	13	
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,57	12,17	11,50
		Conjunto de Validação	14,67	14,72	15,25
	6	Conjunto de Treinamento	11,55	11,21	10,97
		Conjunto de Validação	14,60	15,35	16,22
	9	Conjunto de Treinamento	11,35	10,81	10,60
		Conjunto de Validação	15,56	16,38	16,31
	12	Conjunto de Treinamento	11,00	10,45	9,89
		Conjunto de Validação	15,87	17,10	17,62

Tabela III.29 – Indicador de Desempenho – Modelo M02qRNA –Valores Individualizados

Erro Percentual Médio Absoluto (EPMA) – Retirada dos Açudes Pacoti/Riachão		Número de Nós - Camada Oculta 1			
		7	10	13	
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	8,94	8,82	8,37
		Conjunto de Validação	10,69	10,48	10,85
	6	Conjunto de Treinamento	8,32	8,64	8,18
		Conjunto de Validação	10,73	10,44	10,59
	9	Conjunto de Treinamento	8,35	8,20	7,72
		Conjunto de Validação	11,28	10,86	11,54
	12	Conjunto de Treinamento	8,59	8,04	7,07
		Conjunto de Validação	10,81	11,45	12,94

Erro Percentual Médio Absoluto (EPMA) – Retirada do Açude Pacajus		Número de Nós - Camada Oculta 1			
		7	10	13	
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	12,69	12,12	11,82
		Conjunto de Validação	13,95	14,00	14,89
	6	Conjunto de Treinamento	11,89	10,98	11,39
		Conjunto de Validação	14,20	15,31	15,55
	9	Conjunto de Treinamento	11,51	10,73	11,00
		Conjunto de Validação	14,65	15,40	15,83
	12	Conjunto de Treinamento	11,16	10,94	10,48
		Conjunto de Validação	15,40	15,38	16,60

Erro Percentual Médio Absoluto (EPMA) – Retirada do Canal do Trabalhador		Número de Nós - Camada Oculta 1			
		7	10	13	
Número de Nós - Camada Oculta 2	0	Conjunto de Treinamento	16,09	15,57	14,31
		Conjunto de Validação	19,37	19,68	20,00
	6	Conjunto de Treinamento	14,44	14,01	13,35
		Conjunto de Validação	18,87	20,29	22,52
	9	Conjunto de Treinamento	14,19	13,50	13,08
		Conjunto de Validação	20,74	22,89	21,57
	12	Conjunto de Treinamento	13,23	12,36	12,12
		Conjunto de Validação	21,40	24,47	23,32