

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

INSTITUTO DE PESQUISAS HIDRÁULICAS

**PREVISÃO EM TEMPO ATUAL DE CHEIAS COM USO DE SISTEMA
ESPECIALISTA DIFUSO**

OLAVO CORREA PEDROLLO

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

Porto Alegre, Dezembro de 2000.

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 a orientação do Professor Antônio Eduardo Lanna, da Universidade Federal do Rio Grande do sul.

Gostaria de agradecer o apoio recebido durante a realização deste trabalho a diversas pessoas e instituições :

- Ao orientador, Antônio Eduardo Lanna, pela confiança e estímulo durante o desenvolvimento dos trabalhos, e da Tese em particular;
- Aos professores do Departamento de Obras Hidráulicas (DOH), do IPH, ao qual estou vinculado, pela compreensão e apoio que resultou em minha liberação para a conclusão dos estudos;
- Aos funcionários do IPH, especialmente as bibliotecárias, pelos auxílios prestados;
- Às instituições e pessoas que forneceram os dados hidrológicos, essenciais para a execução da pesquisa, especialmente a Aneel (Agência Nacional de Energia Elétrica) e a CEEE (Companhia Estadual de Energia Elétrica);
- Aos demais colegas da UFRGS, professores e funcionários, pelo apoio e companheirismo;
- À Márcia e ao Guilherme, principalmente, pela compreensão, motivação e incentivo.

A

Marieta Flores Correa, minha mãe,

De cuja dedicação, confiança e incentivo obtive motivação, esperança e fé no estudo e no esforço pessoal como meios para o progresso.

Resumo

PREVISÃO EM TEMPO ATUAL DE CHEIAS COM USO DE SISTEMA ESPECIALISTA DIFUSO

Sistemas de previsão de cheias podem ser adequadamente utilizados quando o alcance é suficiente, em comparação com o tempo necessário para ações preventivas ou corretivas. Além disso, são fundamentalmente importantes a confiabilidade e a precisão das previsões.

Previsões de níveis de inundação são sempre aproximações, e intervalos de confiança não são sempre aplicáveis, especialmente com graus de incerteza altos, o que produz intervalos de confiança muito grandes. Estes intervalos são problemáticos, em presença de níveis fluviais muito altos ou muito baixos.

Neste estudo, previsões de níveis de cheia são efetuadas, tanto na forma numérica tradicional quanto na forma de categorias, para as quais utiliza-se um sistema especialista baseado em regras e inferências difusas. Metodologias e procedimentos computacionais para aprendizado, simulação e consulta são idealizados, e então desenvolvidos sob forma de um aplicativo (SELF – Sistema Especialista com uso de Lógica “Fuzzy”), com objetivo de pesquisa e operação.

As comparações, com base nos aspectos de utilização para a previsão, de sistemas especialistas difusos e modelos empíricos lineares, revelam forte analogia, apesar das diferenças teóricas fundamentais existentes.

As metodologias são aplicadas para previsão na bacia do rio Camaquã (15543 km²), para alcances entre 10 e 48 horas. Dificuldades práticas à aplicação são identificadas, resultando em soluções as quais constituem-se em avanços do conhecimento e da técnica.

Previsões, tanto na forma numérica quanto categorizada são executadas com sucesso, com uso dos novos recursos. As avaliações e comparações das previsões são feitas utilizando-se um novo grupo de estatísticas, derivadas das frequências simultâneas de ocorrência de valores observados e preditos na mesma categoria, durante a simulação.

Os efeitos da variação da densidade da rede são analisados, verificando-se que sistemas de previsão pluvio-hidrométrica em tempo atual são possíveis, mesmo com pequeno número de postos de aquisição de dados de chuva, para previsões sob forma de categorias difusas.

Palavras-chave : previsão em tempo atual, sistemas especialistas, lógica fuzzy.

Abstract

REAL-TIME FLOOD FORECASTING USING FUZZY EXPERT SYSTEMS

Flood forecasting systems are only useful when the forecast lead time is longer than the time required to activate preventive or remedial actions. In addition, the reliability and accuracy of forecasts are of prime importance.

Flood level forecasts are always approximations, and confidence intervals are not always suitable, particularly with low confidence probabilities, which results intervals that are too wide. These intervals are troublesome, therefore, in the presence of very low and very high river levels.

In this study, flood level forecasts are tried, both in the traditional, numerical form, and in the form of vague categories. It is accomplished using an expert system based on fuzzy rules and fuzzy inference. Methodologies and computational procedures for learning, simulation and consultation are idealised and then developed as a software (SELF - Sistema Especialista com uso de Lógica Fuzzy), which is aimed at research and practical operation.

Comparisons between the use for prediction of fuzzy systems and empirical linear models revealed strong similarities, in spite of the fundamental differences in theory.

The methodologies are applied to real time river level forecasts in the Camaquã river basin (15543 km²), for lead times ranging from one half to two days. Practical difficulties related to the use of fuzzy systems are identified and explored. The solutions found offer some advances to knowledge and practical application.

Forecasts, both in the numerical and categorical forms, are made successfully, using the new resources. Evaluation and comparison of the predictions in symbolic form are made with the use of a proposed new group of statistics, derived from frequencies of simultaneous occurrences of observed and predicted values at the same categories.

The effects of raingauge network density are analysed, and it is found that forecasting systems may be operated even where network density is sparse, given that fuzzy expert systems are available for symbolic predictions.

Keywords : Real-time forecasting, expert systems, fuzzy logic.

Sumário

APRESENTAÇÃO	i
RESUMO	ii
ABSTRACT	iii
SUMÁRIO	iv
LISTA DE TABELAS	vi
LISTA DE FIGURAS	vii
LISTA DE SÍMBOLOS	ix
1. INTRODUÇÃO	1
1.1. A CARACTERIZAÇÃO DO PROBLEMA	1
1.1.1. AS ENCHENTES E A REDUÇÃO DE DANOS	1
1.1.2. AS PREVISÕES DE CURTO PRAZO	6
1.2. OS OBJETIVOS DA PESQUISA	8
2. REVISÃO BIBLIOGRÁFICA	9
2.1. OS MODELOS PARA A PREVISÃO DE CURTO PRAZO	9
2.2. OS MODELOS EMPÍRICOS LINEARES	12
2.2.1. APRESENTAÇÃO E DESCRIÇÃO	12
2.2.2. TÉCNICAS DE AJUSTE	14
2.2.3. PREVISÕES APROXIMADAS : LIMITES DE CONFIANÇA	17
2.3. OS SISTEMAS ESPECIALISTAS DIFUSOS	19
2.3.1. APRESENTAÇÃO E DESCRIÇÃO	19
2.3.1.1. INTRODUÇÃO	19
2.3.1.2. FUNDAMENTOS TEÓRICOS	22
2.3.1.3. PROCEDIMENTOS FUNCIONAIS	27
2.3.2. TÉCNICAS DE APRENDIZADO	35
2.3.3. PREVISÕES APROXIMADAS : CATEGORIAS	44
2.4. A QUALIDADE DAS PREVISÕES	46

3. METODOLOGIA	48
3.1. CONSIDERAÇÕES GERAIS	48
3.2. A ESTRUTURA E OS RECURSOS DO SELF	50
3.2.1. GENERALIDADES	50
3.2.2. OS CONJUNTOS DIFUSOS	52
3.2.3. AS BIBLIOTECAS DE CONHECIMENTO	54
3.2.4. AS OPÇÕES METODOLÓGICAS	56
3.2.5. A CONSULTA E A SIMULAÇÃO	58
3.2.6. O APRENDIZADO	65
3.2.6.1. GENERALIDADES	65
3.2.6.2. APRENDIZADO ORGANIZATIVO	66
3.2.6.3. APRENDIZADO ADAPTATIVO	72
3.3. OS ASPECTOS METODOLÓGICOS DA APLICAÇÃO	75
3.3.1. GENERALIDADES	75
3.3.2. A IDENTIFICAÇÃO DOS MODELOS	77
3.3.3. O USO DAS TÉCNICAS DE APRENDIZADO	79
3.3.4. AS PREVISÕES CATEGORIZADAS	80
3.3.5. OS MODELOS EMPÍRICOS LINEARES	82
3.3.6. A REDUÇÃO DA REDE DE AQUISIÇÃO	84
4. APLICAÇÃO E RESULTADOS	85
4.1. CONSIDERAÇÕES GERAIS	86
4.2. A IDENTIFICAÇÃO DOS MODELOS	89
4.3. O USO DAS TÉCNICAS DE APRENDIZADO	93
4.4. AS PREVISÕES CATEGORIZADAS	99
4.5. OS MODELOS EMPÍRICOS LINEARES	101
4.6. A REDUÇÃO DA REDE DE AQUISIÇÃO	109
5. CONCLUSÕES E RECOMENDAÇÕES	114
REFERÊNCIAS BIBLIOGRÁFICAS	121

Lista de Tabelas

Tabela 3.1. Símbolos atribuídos aos conjuntos	53
Tabela 4.1. Estatísticas básicas dos níveis amostrais	87
Tabela 4.2. Postos pluviométricos utilizados	88
Tabela 4.3. Identificação dos modelos autoregressivos : Ep (cm)	90
Tabela 4.4. Identificação dos modelos com chuvas parciais : Ep (cm)	91
Tabela 4.5. Identificação dos modelos com chuvas totais : Ep (cm)	92
Tabela 4.6. Variação do número de categorias de chuvas	92
Tabela 4.7. Variação do número de categorias de níveis	93
Tabela 4.8. Desempenho dos procedimentos do Aprendizado Organizativo : Ep (cm)	94
Tabela 4.9. Desempenho dos procedimentos do Aprendizado Adaptativo : Ep (cm)	95
Tabela 4.10. Resumo dos ganhos com os processos de aprendizado	96
Tabela 4.11. Coeficientes de agrupamento obtidos na verificação das previsões	99
Tabela 4.12. Parâmetros ajustados para os modelos empíricos lineares	102
Tabela 4.13. Desempenho comparativo dos modelos	107
Tabela 4.14. Novas posições dos protótipos extremos	110
Tabela 4.15. Perda de eficiência (%) : Conjuntos Originais (O) e modificados (M)	110
Tabela 4.16. Desempenho comparativo por número de postos pluviométricos	112

Lista de Figuras

Figura 1.1. Alcances das previsões	8
Figura 2.1. Intervalos probabilísticos de confiança	18
Figura 2.2. Categorias de tempo	20
Figura 2.3. Aproximação de funções	21
Figura 2.4. Conjunto das pessoas jovens	23
Figura 2.5. Funções de pertinência : Tipos padrões	24
Figura 2.6. Número difuso “em torno de 12”	24
Figura 2.7. Características dos conjuntos difusos	25
Figura 2.8. Superposição de conjuntos difusos	26
Figura 2.9. Conjuntos triangular e trapezoidal	26
Figura 2.10. Operações de Interseção e de União	26
Figura 2.11. Determinação do grau de acionamento	29
Figura 2.12. Funções de pertinência ao conjunto resultante	30
Figura 2.13. Método clássico de composição	31
Figura 2.14. Comparação das técnicas de composição	31
Figura 2.15. Alguns métodos para desquantização	32
Figura 2.16. Inferência em sistemas difusos	33
Figura 2.17. Pesquisa de regras por análise de agrupamentos	37
Figura 2.18. Determinação do conseqüente da regra associativa	37
Figura 2.19. FAM : “Fuzzy Associative Memories”	38
Figura 2.20. Auto-organização amostral por registros	39
Figura 2.21. FAM numericamente rotulada	41
Figura 2.22. Auto-organização amostral por regras	42
Figura 3.1. SELF : Tela principal	51
Figura 3.2. Tipos de conjuntos difusos do SELF	53
Figura 3.3. Sistemas difusos e modelos convencionais	58
Figura 3.4. A consulta : Descrição dos procedimentos	59
Figura 3.5. A consulta : Exemplo de uso	60

Figura 3.6. Simulação com Verificação	62
Figura 3.7. Emissão dos resultados e estatísticas de desempenho	63
Figura 3.8. Domínio dos coeficientes de agrupamento	64
Figura 3.9. Representação do elemento matricial $(x_h, y_i; z_j) : \omega_r$	66
Figura 3.10. Agrupamento no limite entre conjuntos	68
Figura 3.11. Matriz cognitiva : Agregação de conhecimentos	69
Figura 3.12. Pesquisa das regras na matriz cognitiva	70
Figura 3.13. Aprendizado F-Organizativo Acumulativo	72
Figura 3.14. Variação dos protótipos	73
Figura 3.15. Aprendizado Tipo-Adaptativo : Uma variável	74
Figura 3.16. Combinação de regras nos modelos autoregressivos	78
Figura 3.17. Uso dos procedimentos Adaptativos	80
Figura 3.18. Transformação para conjuntos difusos : Exemplo	81
Figura 3.19. Mecanismo de transformação através do SELF	82
Figura 4.1. Bacia do rio Camaquã	86
Figura 4.2. Curva de permanências de níveis	87
Figura 4.3. Correlogramas dos erros do sistema especialista : Alcance $\frac{1}{2}$ dia	97
Figura 4.4. Correlogramas dos erros do sistema especialista : Alcance 1 dia	97
Figura 4.5. Correlogramas dos erros do sistema especialista : Alcance $1 \frac{1}{2}$ dias	98
Figura 4.6. Correlogramas dos erros do sistema especialista : Alcance 2 dias	98
Figura 4.7. Previsões em categorias combinadas	101
Figura 4.8. Correlogramas dos erros do modelo empírico : Alcance $\frac{1}{2}$ dia	102
Figura 4.9. Correlogramas dos erros do modelo empírico : Alcance 1 dia	103
Figura 4.10. Correlogramas dos erros do modelo empírico : Alcance $1 \frac{1}{2}$ dias	103
Figura 4.11. Correlogramas dos erros do modelo empírico : Alcance 2 dias	104
Figura 4.12. Previsões : Alcance de $\frac{1}{2}$ dia	105
Figura 4.13. Previsões : Alcance de 1 dia	105
Figura 4.14. Previsões : Alcance de $1 \frac{1}{2}$ dias	106
Figura 4.15. Previsões : Alcance de 2 dias	106
Figura 4.16. Previsões com alcance de 1 dia em função do número de postos	111

Lista de Símbolos

- CP, CS = Referências genéricas aos conjuntos principal e secundário, em resposta a uma consulta;
- Ex = Erro máximo, em uma simulação com verificação;
- Fc = Fator de confiança do registro;
- Foc = Freqüência de ocorrências combinadas : Freqüência com que $\mu_{CP}(u_{t+\tau}) > 0,5$ ou $\mu_{CS}(u_{t+\tau}) > 0,5$, em uma simulação;
- Fop = Freqüência de ocorrências parciais : Freqüência com que $\mu_{CP}(u_{t+\tau}) > 0$, em uma simulação;
- Fot = Freqüência de ocorrências totais : Freqüência com que $\mu_{CP}(u_{t+\tau}) > 0,5$, em uma simulação;
- Gac = Grau de acionamento, ou grau de pertinência atribuído ao conseqüente na aplicação de uma regra associativa;
- M () = Matriz cognitiva, com uma dimensão para cada variável (explicativas + explicada), cujos elementos representam o número ponderado de ocorrências, após a aplicação de um procedimento de aprendizado Organizativo;
- nF = Número de falhas de conhecimento, em uma simulação;
- Pe = Perda de eficiência, resultante de uma simplificação imposta, ou aos dados utilizados, ou ao modelo;
- Sq = Somatório dos quadrados dos erros, ou função quadrática;
- u_t e \hat{u}_t = Valores da variável explicada, observados ou medidos e calculados ou estimados, respectivamente, no tempo atual t;
- $\hat{u}_{t+\tau}$ = Valor previsto da variável explicada, para o alcance τ ;
- $\hat{u}_{a_{t+\tau}}$ = Valor previsto da variável explicada, para o alcance τ , com modelo alternativo;
- α_i = Parâmetros ajustados para o modelo empírico linear;
- $\mu_A(x)$ = Grau de pertinência do valor x ao conjunto difuso A;
- ω_r = Ponderação atribuída a cada regra;

1. Introdução

1.1. A Caracterização do Problema

1.1.1. As Enchentes e a Redução de Danos

A importância dos excessos ou da escassez da água, entre os desastres naturais, evidencia-se pelas estatísticas da WMO (World Meteorological Office), publicadas por Askew (1997). Tem-se que 54% dos danos significativos, 65% das pessoas afetadas e 29% das mortes provocadas por desastres naturais são devidas a inundações ou estiagens. Segundo o autor, o Twelfth World Meteorological Congress, de 1995, salienta que inundações e estiagens sempre ocorreram e sempre ocorrerão, razão pela qual é essencial que as ações para a redução de seus efeitos sejam um objetivo permanente e de longo prazo.

O problema de enchentes é muito antigo, porém agrava-se com o incremento da ocupação humana. Principalmente, a urbanização indiscriminada em planícies de inundações, cria situações extremamente perigosas.

No Brasil, além da ocupação de planícies de inundação, observa-se a ocupação crescente, em grandes centros, de zonas altas, os chamados morros. A ocupação dos morros, como única opção viável economicamente para os socialmente desfavorecidos, reveste-se de grande importância, uma vez que, com relação a enchentes, existem múltiplas conseqüências.

Por um lado, chuvas intensas, sobre superfícies das quais foi retirada a cobertura vegetal para ocupação, resultam em enxurradas, as quais provocam desabamentos, com perdas de vidas e dos bens imóveis, muitas vezes construídos ilegalmente. Desmoronamentos podem constituir-se em quedas de barreiras, com conseqüências danosas nas estradas.

A retirada da cobertura vegetal intensifica os processos erosivos, indo depositar-se os materiais resultantes nos canais fluviais. Como conseqüência, tem-se redução na capacidade das calhas dos rios, e aumento da ocorrência de enchentes.

Acrescendo-se a isso o fato de existirem possíveis mudanças climáticas em curso, com conseqüente aumento de índices pluviométricos em algumas regiões, conclui-se que o problema das enchentes tende a agravar-se.

Tradicionalmente, os meios para redução de danos causados por inundações têm sido classificados em estruturais (intervenções sob forma de obras de engenharia), e não estruturais.

As medidas estruturais podem ser classificadas em medidas extensivas e medidas intensivas (Cordero et alii, 1998). As extensivas implicam em alteração na bacia hidrográfica, no que diz respeito, principalmente, à ocupação e cobertura dos solos.

As medidas estruturais intensivas são localizadas, podendo-se citar, principalmente, a construção de diques (acompanhados de sistemas de drenagem), a modificação do canal para aumentar sua capacidade de escoamento, bacias de retenção, para armazenamento temporário dos volumes excedentes em áreas de inundação, e reservatórios para regularização.

Diques são meios úteis para a proteção contra enchentes, porém podem desviar as águas de cheias para outras áreas desprotegidas, além de servirem de incentivo à ocupação, o que pode ser perigoso, caso o nível de projeto seja excedido.

O aumento da capacidade de escoamento da calha fluvial pode ser obtido simplesmente por dragagem, ou por retificação, ou construção ou ampliação de canais, e resulta em efeitos localizados, porém pode causar problemas de erosão e sedimentação, além de transferir os problemas de inundação para outras áreas.

Bacias de retenção utilizam-se de áreas de armazenamento natural, para redução das descargas de pico a jusante, sendo simples e de construção pouco dispendiosa. Porém, áreas inundadas sofrem danos durante enchentes, existem riscos para os moradores locais, e a eficiência é limitada à capacidade de armazenamento.

Reservatórios para regularização de descargas podem ser construídos com uso múltiplo, o que permite o compartilhamento dos custos. Porém, provocam inundação permanente de áreas que podem ser extensas, requerendo as suas desocupações. Além disso, os danos ambientais e alterações morfológicas podem ser relevantes.

As medidas estruturais podem ser implementadas em áreas com pouca pressão antrópica. À medida que crescem os índices de ocupação aumentam as necessidades de medidas não estruturais.

Entre as medidas não estruturais, são importantes o planejamento e gerenciamento do uso do espaço físico, o seguro contra enchentes, e sistemas de previsão e alerta contra cheias, além de medidas complementares a estas, como informação e educação pública e medidas de evacuação emergencial.

A especificação e fiscalização do uso das áreas sujeitas, com maior ou menor risco, a inundações, em função do risco existente, permite o uso do espaço físico de forma consistente, garantindo que os prejuízos não serão agravados pelo desenvolvimento da ocupação, além de preservar-se o meio ambiente e paisagístico.

O seguro contra enchentes transfere a responsabilidade pela opção por residir em áreas de risco para os indivíduos, aliviando os custos dos poderes públicos. Porém, é difícil obter-se a adesão das companhias privadas de seguro.

Sistemas de previsão e alerta são efetivos quando associados a outras medidas, como a divulgação de mapas de inundação, com a exposição de regiões a serem alagadas. A educação do público potencialmente afetado, para interpretação das informações divulgadas e providências pessoais, é fundamental.

Além disso, comportas de diques e barragens são controladas em função das previsões. Estas são úteis também para a ação da defesa civil, das ações de resgate, evacuação de pessoas para locais seguros, instalação de postos médicos e centros de auxílio.

Embora o controle total de inundações seja praticamente impossível, é indispensável para a proteção de vidas humanas e de benfeitorias, bem como manutenção ou reposição de serviços essenciais e proteção ambiental, a existência de medidas para redução dos danos provocados por enchentes.

O controle efetivo de cheias depende, freqüentemente, da combinação apropriada de medidas estruturais e não estruturais. Todini (1998) recomenda o uso integrado e seqüencial de quatro principais medidas não estruturais, as quais são :

- Identificação de áreas de alta incidência de enchentes, e desenvolvimento de mapas de risco de inundação;
- Instalação de sistemas confiáveis de previsão e alerta, o qual estabeleça um tempo de antecedência operacional de, pelo menos, 6 horas (se possível, 12 ou mais);
- Definição dos planos de emergência para situações de risco, elaboração de manuais específicos de conduta, com informações para cada área, bem como a delimitação da área ameaçada, os riscos envolvidos, as autoridades responsáveis, ações a empreender, a quem alertar, etc.;
- Desenvolvimento de um sistema de suporte à decisão, com objetivo de centralizar as operações em uma unidade operacional para emergências, e monitorar e coordenar as atividades dos grupos envolvidos nas ações para alívio dos efeitos das inundações.

Segundo o autor, um sistema de suporte à decisão para planejamento, alerta e controle de cheias deve atender às necessidades dos usuários finais. O sistema total de planejamento e alerta consiste de duas partes, ou seja, a parte tecnológica e a parte sociológica.

O subsistema tecnológico é operado por meteorologistas e hidrólogos e consiste na aquisição de dados e nos sistemas de previsão meteorológica, os quais resultam nos dados para os modelos de previsão de cheias e operação das ferramentas de suporte à decisão.

Os dados, os modelos matemáticos e as ferramentas de suporte à decisão são consultados pelos gerentes de operação, os quais, dependendo do caso, emitem alertas à defesa civil. A defesa civil interage com os meios de comunicação, a polícia e o público, diretamente ou indiretamente, formando o subsistema sociológico. Portanto, é evidente a importância das previsões, no contexto das atividades de controle e redução de danos provocados por inundações.

Previsões confiáveis de níveis de inundações são igualmente importantes, tanto na fase de ascensão quanto na recessão. No primeiro caso, ações preventivas são ou não implementadas, com intensidades e, conseqüentemente, custos, variáveis. No segundo caso, o conhecimento do rebaixamento esperado dos níveis fluviais pode auxiliar na orientação de decisões relativas à continuidade das ações e à possibilidade de danos provenientes do prolongamento da enchente.

Previsões com pelo menos seis horas de antecedência podem ser importantes, desde que haja, nestes casos, um estado geral de sobreaviso, tanto das autoridades como do público potencialmente atingível, com base no cenário geral, do qual fazem parte o conjunto de informações hidrológicas e meteorológicas disponíveis e o conhecimento das evoluções possíveis. Porém, o ideal, tendo-se em conta a necessidade de coordenação entre os diversos agentes envolvidos, e o preparo, é uma antecedência de pelo menos 12 horas.

A seqüência de estados de alerta e, portanto, as previsões, precisam ser estruturadas em vários níveis. À medida que o tempo de antecedência das previsões diminui, aumenta a precisão e a confiabilidade. Estes níveis podem ser qualitativos, para horizontes maiores, tendendo para previsões quantitativas para alcances menores.

As previsões podem ser obtidas a partir de informações cada vez mais sofisticadas e completas, à medida que diminui a área da bacia e, conseqüentemente, o tempo de resposta disponível. Por exemplo :

- Bacias grandes ($> 10000 \text{ km}^2$), para as quais os níveis de enchentes à frente podem ser obtidos, em uma ou mais seções, com base unicamente nas descargas (ou níveis), de uma ou mais seções a montante.

- Bacias intermediárias, para as quais as previsões podem ser obtidas com base nas observações das precipitações. Ou seja, as chuvas futuras afetam muito pouco as descargas que ocorrerão, devido ao tempo requerido para o transporte na bacia.
- Bacias pequenas ($< 1000 \text{ km}^2$), para as quais somente são possíveis previsões com antecedência suficiente, quando houver disponibilidade de previsões de chuvas com a precisão adequada.

O sistema da bacia do Itajaí-Açu, com 15.000 km^2 de área, é um exemplo do primeiro caso, onde um modelo estocástico estacionário (Cordero et alii, 1998) vem sendo utilizado para previsões em tempo atual de níveis, com antecedência de até oito horas, para a cidade de Blumenau.

O modelo utiliza, como entradas, os níveis nos postos de Apiúna (o qual controla os volumes provenientes de sudoeste), e Timbó (o qual controla os volumes provenientes do norte), sendo utilizado com sucesso no Centro de Operação do Sistema de Alerta da bacia do rio Itajaí-Açu, desde 1992. Previsões de níveis são fornecidas à defesa civil, a qual, por sua vez, é responsável pelo alerta às pessoas afetadas.

No caso de modelos unicamente de propagação de descargas, à medida que adota-se uma estação mais a montante, para obter-se uma maior antecedência por conta do aumento do tempo de deslocamento da onda de cheia, aumenta-se a imprecisão decorrente das incertezas da bacia incremental. O emprego de um modelo chuva-vazão para o trecho incremental, em conjunto com o modelo de propagação, é uma alternativa nestes casos. Este recurso foi utilizado (Pedrollo e Lanna, 1991), para previsões de curto prazo de níveis de inundações para as cidades de União da Vitória e Porto União, no rio Iguaçu.

A bacia incremental, com 10900 km^2 , a jusante de Fluviópolis, constitui cerca de um terço dos 29200 km^2 de áreas contribuintes em União da Vitória. Enquanto as descargas provenientes de montante são antecedidas por um modelo matemático de propagação de ondas, as previsões das contribuições incrementais resultam do uso de modelos chuva-vazão do tipo empírico linear, providos de técnicas de calibração recursiva.

Estes casos constituem-se em exemplos ilustrativos da necessidade de soluções criativas e específicas para cada situação, uma vez que as particularidades físicas e institucionais, e a disponibilidade de recursos para monitoramento e operação, bem como de dados para estudo e calibração dos modelos, apresentam grande variabilidade.

1.1.2. As Previsões de Curto Prazo

Previsões de curto prazo são baseadas no princípio de que é possível obter-se, no presente (dito “tempo atual”), informações suficientes relacionadas às causas que condicionam um evento em um futuro próximo, para, com uso de modelos que relacionam as variáveis envolvidas, prever, com precisão adequada, o estado de determinada variável que representa este evento.

Estas previsões, também chamadas de previsões em tempo atual, quando aplicadas para prever níveis fluviais, dependem do conhecimento do estado do sistema e dos volumes esperados (observados a montante do rio, ou procedentes das precipitações recentes). O estado atual do sistema é representado pelos níveis atuais observados e pelas condições de umidade dos solos da bacia.

Na prática, porém, são possíveis apenas previsões aproximadas, uma vez que, além dos erros das observações e das inexatidões das hipóteses, formuladas com base em simplificações inevitáveis, existe sempre insuficiência de informações.

A forma mais comum de apresentação das previsões é a numérica ou pontual, embora saiba-se que existe uma imprecisão que pode ser interpretada como erro de previsão. Na prática, este erro pode conduzir ao descrédito e conseqüente perda da utilidade da previsão.

A questão das previsões por intervalos de confiança (modelos empíricos lineares) e por categorias (sistemas especialistas) é importante, uma vez que, freqüentemente, o que é honestamente possível é estabelecer-se limites, com maior ou menor amplitude, para os níveis previstos. O que espera-se é que estes possam ser úteis, mesmo com a imprecisão existente da forma de apresentação. A previsão pode ser imprecisa, mas deve ser confiável.

Como exemplo de insuficiência de informações pode-se lembrar que as ocorrências pluviométricas futuras (entre o presente e o alcance, ou horizonte de previsão), são, normalmente, desconsideradas, devido às dificuldades que a meteorologia encontra para realizar previsões quantitativas de chuvas, exigidas pelos modelos matemáticos.

Mesmo os totais de precipitações ocorridos, e que ainda afetam o futuro, costumam ser conhecidos apenas pontualmente, havendo imprecisão devido às diferentes distribuições espaciais possíveis.

Técnicas alternativas, como as proporcionadas pelo uso de radar meteorológico, exigem recursos para investimentos em equipamentos, infra-estrutura e pessoal qualificado, os quais não parecem estar tornando-se mais disponíveis, especialmente para aplicações em atividades não lucrativas.

Segundo Todini (1992), a relação entre custos e qualidade das aquisições por radares meteorológicos está aquém do que pode-se esperar de redes telemétricas convencionais, além do que, estas são necessárias à sua calibração. Além disso, as previsões de chuvas, baseadas nos deslocamentos de nuvens carregadas, possuem alcances muitos pequenos (30 minutos ou pouco mais), abrangendo, portanto, parte irrelevante do tempo descoberto.

Os modelos de previsão quantitativa de precipitações com base na observação das temperaturas de nuvens geladas por meio de imagens de satélites, somente são operacionais para bacias muito grandes, na zona tropical, para a qual a NASA possui o programa TRMM (Tropical Rainfall Measurements Mission).

Tendo-se em conta as dificuldades existentes, é importante analisar-se o que é possível de ser realizado a partir das informações conhecidas das precipitações e do estado do sistema.

O alcance das previsões, por sua vez, depende das informações disponíveis e do tempo de resposta do sistema. Enquanto a maior parte das contribuições que afetam a variável a ser prevista estiverem no passado, é possível obter-se boas previsões. À medida que alcances maiores são considerados, aumenta a importância das contribuições que ainda estão por ocorrer. Diminui, conseqüentemente, a confiabilidade e a precisão das previsões.

Finalmente, quando o intervalo entre o presente e o horizonte da previsão torna-se suficientemente extenso para conter a maior parte das contribuições que afetam a variável a ser prevista, torna-se impossível obter-se bons resultados, com base unicamente em observações de ocorrências passadas. Neste caso, torna-se importante o uso de previsões de chuvas.

Assim, quanto maior o tempo de resposta (o que, em princípio, ocorre em bacias maiores), maior o alcance da previsão, pois menor a proporção de ocorrências futuras que contribuem significativamente.

Por exemplo, na figura 1.1, tem-se três situações, onde, à medida que maiores quantidades das contribuições intervenientes (\downarrow) na formação da grandeza a ser prevista, proporcionalmente, situam-se entre o presente (t) e o horizonte da previsão ($t + \tau$), devido ao deslocamento deste horizonte, aumenta o intervalo (δ) dentro do qual espera-se, com uma certa probabilidade fixa, que ocorra a variável prevista (\hat{u}). Até que, a partir de um certo alcance (o qual depende do tempo de resposta da bacia), as previsões tornam-se totalmente aleatórias, não tendo sentido o uso dos modelos.




Figura 1.1 - Alcances das previsões.

1.2. Os Objetivos da Pesquisa

Considerando-se a complexidade do problema de previsão em tempo atual, e a emergência das técnicas baseadas em lógica difusa ou “fuzzy”, em particular os sistemas especialistas, diversos aspectos passam a ser objeto de investigação.

As deficiências das metodologias tradicionais, baseadas em modelagem matemática numérica são, principalmente, a incapacidade de processar informações qualitativas, as dificuldades para fornecer previsões sob forma aproximada ou simbólica e, em alguns casos, a inaptidão para reproduzir fenômenos não lineares. Além disso, o conhecimento humano, subjetivo, sobre o funcionamento dos sistemas muitas vezes deixa de ser aproveitado por carência de representação formal compatível com os modelos empregados.

O objetivo principal deste trabalho é a pesquisa de uma técnica alternativa para a modelagem, com finalidade de previsão de variáveis hidrológicas, a qual possibilite a superação de, pelo menos, parte das deficiências acima apontadas. Trabalha-se a hipótese de que modelos representados por regras associativas, baseados em sistemas especialistas com uso de lógica difusa, em muitos casos apresentem soluções aceitáveis. Como objetivos complementares desta pesquisa, tem-se :

- Desenvolvimento e testes de metodologias e recursos computacionais para o efetivo domínio da técnica dos sistemas especialistas difusos com finalidade de previsão de níveis de cheias;
- Verificação da contribuição destas metodologias, em comparação com uma técnica mais tradicional, representada por modelos empíricos lineares;
- Desenvolvimento de técnicas para o uso conjugado de modelos matemáticos tradicionais e sistemas especialistas, associando-se aos primeiros a capacidade de geração de previsões aproximadas, sob a forma de categorias difusas.

2. Revisão Bibliográfica

2.1. Os Modelos para a Previsão de Curto Prazo

Previsões de curto prazo são, tradicionalmente, efetuadas por modelos matemáticos empíricos lineares ou por modelos matemáticos conceituais.

Os modelos empíricos lineares, descritos em Pedrollo e Lanna (1991), são funções de recorrência, as quais não são baseadas na natureza dos fenômenos, dependem de calibração a partir de amostragem, e, devido à sua natureza estatística, podem ter probabilidades associadas às previsões, sob forma de intervalos de confiança.

Modelos matemáticos conceituais, teoricamente, possuem a vantagem de representar os fenômenos hidrológicos envolvidos, embora apresentem dificuldades com respeito à atualização contínua dos parâmetros para acompanhar evoluções em processo. Além disso, estes modelos possuem natureza determinística, porém operam dados parcialmente aleatórios e seus resultados, apresentados sob forma de números exatos, dificilmente coincidem com as observações.

As técnicas para a calibração dos parâmetros de modelos conceituais, embora sua natureza permita, muitas vezes, uma estimativa preliminar, normalmente consistem de um processo, com ou sem algum grau de automação, de busca por tentativas, portanto, empírica.

Neste caso, procura-se minimizar uma função chamada de função-objetivo, que representa um valor agregado dos erros de simulação ou, no caso, de previsão. A sistematização destes procedimentos é intuitiva, consistindo, na alternativa mais simples, em tentativas para cada parâmetro, na direção dos melhores resultados.

Existem, no entanto, diversos graus de sofisticação nos procedimentos, conforme descrito por Johnston e Pilgrim (1976), para ajuste de modelos hidrológicos. Os autores identificam as principais dificuldades, tais como a interdependência entre os parâmetros, a indiferença da função-objetivo e, em certos casos, o risco da aceitação de um mínimo local.

O critério mais comum para interromper as tentativas é a ocorrência de variações muito pequenas na função-objetivo. Quanto a esta, é mais utilizada a função quadrática, a qual consiste no somatório do quadrado dos erros. Esta função é mais sensível aos maiores erros, os quais ocorrem, via de regra, para valores maiores da variável predita. No caso de previsão de níveis de cheia, por exemplo, é a mais indicada.

O problema desta forma de calibração, para previsões de curto prazo, é que os ajustes não são Adaptativos, porque as novas informações pesam pouco, se utilizado todo o histórico para cada novo registro adquirido de dados.

Além disso, podem haver problemas de memória disponível e tempo de processamento, pelo volume de dados acumulado. Uma alternativa atraente, neste caso, é o ajuste de um determinado número mais recente de registros, a cada atualização de parâmetros executada.

Tucci e Clarke (1980) ressaltam a necessidade de utilização das informações mais recentes de precipitações e descargas para atualização de parâmetros de modelos chuva-vazão para previsão em tempo atual. Teoricamente, quanto mais freqüente a atualização das estimativas, melhor o desempenho dos modelos.

Os autores apresentam um procedimento de atualização dos parâmetros aplicável aos modelos conceituais do tipo chuva-vazão, os quais são baseados em reservatórios hipotéticos representativos dos armazenamentos teóricos do ciclo hidrológico.

No método apresentado, supõe-se que as informações do conteúdo destes reservatórios, em um determinado instante inicial, substituem o conhecimento do passado hidrológico da bacia, do qual estes conteúdos resultam. A cada nova informação, os dados correspondentes ao número I_r (intervalos recentes) de intervalos passados, após este instante inicial, são utilizados para ajuste dos parâmetros do modelo. Portanto, I_r funciona como a “memória” da bacia, no que diz respeito a seu comportamento recente.

A busca dos valores ótimos para os cinco parâmetros é executada por um procedimento de busca orientada, chamado de método de rotação das coordenadas.

Observa-se, porém, a relativa complexidade dos recursos necessários, principalmente em termos de investimentos em “softwares” e qualificação de usuários. Além disso, modelos ditos conceituais não associam probabilidades, sob forma de intervalos de confiança, por exemplo, às previsões.

Uma alternativa interessante, para a superação das deficiências, é a conjugação dos chamados modelos conceituais aos modelos empíricos lineares. Cruz et alii (1987) apresentam uma combinação do modelo IPH-II com um modelo ARIMAX (modelo empírico, autoregressivo com média móvel e variável exógena, geralmente vazão em seção fluvial a montante), o qual é utilizado para a previsão dos erros do primeiro, tendo seus parâmetros continuamente atualizados, com a técnica dos mínimos quadrados recursivos.

O aprimoramento dos resultados obtido com o modelo conjugado é atribuído à dependência temporal dos erros do modelo de reservatórios hipotéticos. Os autores sugerem o

uso de modelos conjugados onde o modelo dito conceitual pode ser ainda mais simples, desde que assinala com suficiente aproximação a localização temporal dos picos de cheias.

Modelos híbridos empírico-conceituais são interessantes, principalmente para obter-se intervalos de confiança para as previsões realizadas pelos modelos chamados conceituais, bem como associar a estes a capacidade dos modelos empíricos lineares para a atualização contínua dos parâmetros, o que resulta em adaptação a processos em evolução.

Porém, intervalos de confiança probabilísticos podem ser problemáticos, o que deve ser a razão pela qual previsões por intervalos não aparecem com muita freqüência na literatura.

Tendo-se em conta a extensão do assunto da modelagem hidrológica, esta pesquisa utiliza, como referência e comparação, os modelos ditos empíricos.

Os modelos empíricos lineares utilizam dados anteriores e atuais da própria variável, e de outras (variáveis exógenas), para executar as previsões para um alcance determinado. São os chamados modelos ARIMAX, cujo ajuste pode ser feito pela técnica recursiva dos mínimos quadrados (Lanna e Valença, 1985), por exemplo.

Estes modelos, por serem lineares, possuem limitações adicionais quanto ao alcance da previsão, as quais podem ser contornadas, por exemplo, com o uso de transformações prévias das precipitações, para representar as variações nas condições de umidade do solo (Pedrollo, 1999). Para alcances pequenos, porém, a hipótese de linearidade pode, com freqüência, ser satisfatória. Além disso, o uso de técnicas recursivas de ajuste, neste aspecto, contribui significativamente.

Os sistemas especialistas difusos, por sua vez, são aproximadores universais de funções (Kasabov, 1996), sendo naturalmente não-lineares, além de não-paramétricos, o que lhes confere ampla aplicabilidade.

A utilização de sistemas especialistas para previsão possui uma forte analogia com o uso dos modelos empíricos, uma vez que opera séries temporais de entrada, as quais estão relacionadas à série temporal de saída do sistema, que é composta das previsões individuais para cada registro processado. Além disso, é necessário, freqüentemente, a extração de conhecimento, a partir de amostras, sobre o comportamento conjunto das variáveis envolvidas, o que é uma característica de modelos empíricos, no que diz respeito ao ajuste de parâmetros.

Finalmente, a maior parte dos trabalhos com modelos de previsão de curto prazo tem sido executada com análise de eventos individuais observados.

Neste caso, os modelos são ajustados para reproduzir a forma dos hidrogramas ou dos linigramas de cheias, com o conhecimento prévio de suas ocorrências.

Problemas podem aparecer quando o modelo, ajustado nestas condições, é utilizado em situações práticas, onde o previsor não sabe, com antecedência, se está para ocorrer um evento de cheia. Nestes casos, podem resultar valores absurdos, perdendo-se a credibilidade da previsão, sem a qual esta não tem utilidade.

2.2. Os Modelos Empíricos Lineares

2.2.1. Apresentação e Descrição

Um modelo empírico de previsão é, basicamente, uma equação de recorrência onde os valores previstos são obtidos a partir de valores anteriores das variáveis intervenientes no processo. Não existindo a preocupação de representar o conhecimento do fenômeno através de leis físicas, os parâmetros são obtidos através do ajuste às realizações passadas.

Estes modelos, uma vez que não fornecem explicações sobre o funcionamento dos fenômenos, mas apenas os resultados, são referidos como modelos “caixas pretas”. Possuem, porém, algumas vantagens importantes, tais como poder associar probabilidades de ocorrência aos eventos futuros, e a simplicidade de cálculo.

Os modelos empíricos lineares são utilizados na simulação de séries hidrológicas, por exemplo. Tem-se, tradicionalmente, os modelos Autoregressivos (AR), Médias móveis (MA), e Autoregressivos com médias móveis (ARMA).

Modelos autoregressivos têm sido aplicados com sucesso para representar séries temporais, e mesmo para previsão. As baixas vazões, nas estações secas principalmente, resultam principalmente de contribuições subterrâneas, as quais têm relativamente pequena variação. Durante os períodos de recessão, as vazões ao final de um certo intervalo são frações das descargas nos intervalos precedentes, o que pode (Salas et alii, 1978), ser representado por um esquema autoregressivo AR(p), sendo p o número de componentes autoregressivas :

$$\hat{u}_t = \mu + \phi_1 (u_{t-1} - \mu) + \dots + \phi_p (u_{t-p} - \mu) + \varepsilon_t, \quad (2.1)$$

onde u_t representa uma série temporal dependente com média μ , ε_t uma série temporal independente com média zero e variância constante, e ϕ_1, \dots, ϕ_p um número finito p de parâmetros autoregressivos, e \hat{u}_t os valores calculados ou estimados.

O comportamento do modelo nas ascensões pode ser representado com a adição de um número finito q de variáveis aleatórias independentes, resultando nos chamados modelos mistos autoregressivos com média móvel ARMA(p, q) :

$$\hat{u}_t = \mu + \phi_1 (u_{t-1} - \mu) + \dots + \phi_p (u_{t-p} - \mu) + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}, \quad (2.2)$$

onde $\theta_1, \dots, \theta_q$ correspondem aos parâmetros das componentes de média móvel.

Os processos complexos que ocorrem na bacia hidrográfica podem ser explicados, segundo Salas et alii (1980), por modelos empíricos lineares deste tipo. Os “ p ” termos autoregressivos estão relacionados ao fenômeno do armazenamento, enquanto que “ q ” depende do tempo de resposta da bacia às precipitações.

Diferenciações nas séries temporais são executadas, para gerar séries estacionárias, as quais conduzem a modelos com menor número de parâmetros. Este procedimento, quando combinado com os modelos ARMA(p, q) constitui-se na técnica dos modelos Autoregressivos com Médias Móveis Integrados, ARIMA(p, d, q), os quais, podem ser utilizados para previsão.

Uma generalização possível deste modelo é obtida com a introdução de variáveis exógenas, as quais representam qualquer informação que possa ser introduzida para incrementar a qualidade das previsões.

Estes modelos, assim definidos, podem ser chamados de modelos ARIMAX(p, d, q, r), onde o “ I ” refere-se à diferenciação, e o “ X ” às variáveis exógenas. Os termos d e r são, respectivamente, o número de diferenciações e o número de variáveis exógenas. Cada variável exógena pode contribuir com uma ou mais componentes, por isso são importantes os conceitos de “memória” (MEM) e “atraso” (ATR) associados.

De acordo com Pedrollo e Lanna (1991), a “memória” significa a extensão de tempo, a partir do momento atual em direção ao passado, em que os valores assumidos pela variável ainda podem afetar o sistema. Em modelos chuva-vazão a “memória” depende, portanto, do tempo de resposta da bacia às precipitações. O “atraso”, por sua vez, significa a partir de que intervalo, em direção ao passado, estas informações passam a ter importância para a previsão.

Pode-se exemplificar com o modelo ARIMAX(1,1,0,1), onde MEM = 1 e ATR = 0 para a variável exógena x . A formulação do modelo de previsão da variável u , considerando-se alcance τ , pode ser :

$$\hat{u}_{t+\tau} = u_t + a (u_t - u_{t-1}) + \alpha_3 x_t + \varepsilon_t, \quad (2.3)$$

onde ε_t representa os erros aleatórios. Pode-se, porém, reformular o modelo acima, por manipulação algébrica :

$$\hat{u}_{t+\tau} = (1+a) u_t + (-a) u_{t-1} + \alpha_3 X_t + \varepsilon_t \quad (2.4)$$

Ou seja, fazendo-se $\alpha_1 = (1+a)$ e $\alpha_2 = -a$, resulta :

$$\hat{u}_{t+\tau} = \alpha_1 u_t + \alpha_2 u_{t-1} + \alpha_3 X_t + \varepsilon_t \quad (2.5)$$

Portanto, a principal vantagem de diferenciações de variáveis para modelos de previsão consiste na economia de parâmetros, o que poderia ser importante no caso de haver limitações na capacidade dos recursos computacionais disponíveis para o ajuste.

Além disso, certas técnicas de pesquisa e ajuste baseiam-se na análise de correlogramas amostrais, os quais exigem estacionaridade das séries, o que pode ser obtido, entre outros recursos, pela diferenciação sucessiva.

A linearidade da formulação, porém, praticamente elimina estas possíveis dificuldades, uma vez que permite o uso de algoritmos de calibração dos parâmetros em tempo atual, o que resulta em adaptações a modificações dos processos ao longo do tempo. Entre estes, tem sido particularmente importante o uso do método dos mínimos quadrados recursivos, pela relativa facilidade de programação e pela qualidade dos resultados obtidos.

2.2.2. Técnicas de Ajuste

O ajuste empírico de modelos matemáticos a dados amostrais, em seu sentido mais amplo, possui três aspectos importantes a serem hierarquicamente considerados :

- O primeiro é identificar-se quais, entre as variáveis e componentes destas, representadas nos conjuntos de registros amostrais, afeta os resultados ou previsões desejados. Por exemplo, pode ser que a segunda componente autoregressiva seja importante, mas a terceira não o seja;
- O segundo, implica em descobrir-se a natureza da função que relaciona as variáveis. No caso do uso de modelos empíricos lineares, pode ser que algum tipo de transformação seja necessária, para ter-se em conta possíveis não-linearidades do processo;

- E, finalmente, a calibração dos parâmetros, buscando-se os valores que proporcionam o ajuste desejado do modelo.

Nos dois primeiros aspectos, a experiência prévia e a experimentação são, normalmente, os elementos necessários à sua execução, embora existam recursos auxiliares para a análise. Quanto ao terceiro, existem técnicas, de natureza estatística, que são utilizadas para a calibração.

O método conceitualmente mais simples (e mais generalizável, uma vez que não limita-se a modelos lineares), é a maximização ou minimização de uma função-objetivo, a qual representa o grau de ajuste obtido. No caso de modelos hidrológicos, a função-objetivo deve ser uma medida da magnitude dos erros de previsão, como, por exemplo, a função quadrática (somatório do quadrado dos erros) :

$$S_q = \sum_t (\hat{u}_t - u_t)^2, \quad (2.6)$$

o qual favorece o ajuste aos valores maiores da variável explicada.

No processo de calibração por tentativas, vários parâmetros ou conjuntos de parâmetros são testados, de forma orientada, optando-se pelo que apresenta um valor mais favorável para a função-objetivo.

Devido à relativa simplicidade das formulações empregadas, é possível, para os modelos empíricos lineares, obter-se funções-objetivo explicitamente dependentes dos parâmetros, o que permite o ajuste através de técnicas de inferência de origem estatística.

Os métodos tradicionais de ajuste de modelos estocásticos (Salas et alii, 1980) são o método dos momentos, o método da máxima verossimilhança e o método dos mínimos quadrados. Normalmente, as propriedades utilizadas para avaliar a qualidade dos estimadores são a tendenciosidade e a variância dos parâmetros.

Considerando-se um problema de regressão, dado pela relação :

$$U = X^T A + \varepsilon \quad (2.7)$$

As variáveis linearmente independentes (X) são quantidades medidas sem erro, enquanto que a variável dependente (U) está sujeita à interferência da perturbação ε , cuja seqüência forma uma série de valores aleatórios independentes das variáveis explicativas, não autocorrelacionados, com valor esperado nulo e variância constante.

A técnica dos mínimos quadrados consiste na estimativa dos parâmetros (A) pela minimização da soma dos quadrados dos erros, a qual resulta nas chamadas equações normais, representadas por :

$$A_k = P_k B_k, \quad (2.8)$$

onde :

$$P_k = [\sum_{i=1, k} X_i X_i^T]^{-1}; \quad B_k = \sum_{i=1, k} X_i u_i \quad (2.9)$$

Independentemente de qual seja a distribuição de probabilidade dos erros, segundo Draper et Smith (1981), as estimativas de mínimos quadrados dos parâmetros resultam, para um modelo adequado, estimativas não-tendenciosas com mínima variância.

Pela forma de somatório que adquirem estas equações, verifica-se que seus valores podem ser atualizados a partir dos resultados anteriores, para cada nova observação, tendo-se :

$$P_{k-1} = P_{k-1}^{-1} + X_k X_k^T, \quad e \quad (2.10)$$

$$B_k = B_{k-1} + X_k u_k, \quad (2.11)$$

as quais constituem uma solução recursiva para os mínimos quadrados, as quais, para facilidade de manipulação, podem ser transformadas algebricamente (Young, 1974), nas equações :

$$A_k = A_{k-1} - P_k [X_k X_k^T A_{k-1} - X_k u_k], \quad (2.12)$$

onde :

$$P_k = P_{k-1} - P_{k-1} X_k [1 + X_k^T P_{k-1} X_k]^{-1} X_k^T P_{k-1} \quad (2.13)$$

Estas equações constituem um algoritmo eficiente de cálculo, onde k representa a última atualização realizada. Este algoritmo possui vantagens significativas em relação à técnica convencional (equações normais), especialmente devido à natureza escalar do resultado da expressão :

$$[1 + X_k^T P_{k-1} X_k]^{-1}, \quad (2.14)$$

uma vez que a inversão constitui-se em uma simples operação algébrica, no lugar da inversão de matriz que ocorre na técnica dos mínimos quadrados convencional. Além disso, a cada nova atualização, necessitamos apenas dos parâmetros anteriores e da matriz P_{k-1} , a qual será também atualizada para P_k , não necessitando, do armazenamento das matrizes X e U .

2.2.3. Previsões Aproximadas : Limites de Confiança

Devido às componentes aleatórias participantes, as previsões serão sempre diferentes dos valores verdadeiros. Embora previsões pontuais sejam freqüentemente adequadas, se suficientemente aproximadas, um intervalo de previsão é sempre útil para quantificar incertezas, podendo ser calculado empiricamente a partir das séries de erros.

No caso de modelos matemáticos empírico-lineares os intervalos são, usualmente, os limites de confiança de natureza probabilística, os quais dependem de uma hipótese preliminar sobre a distribuição de probabilidade dos erros.

Felizmente, como estes modelos são combinações lineares de variáveis aleatórias, resultam com freqüência séries de erros com distribuição suficientemente próxima da distribuição normal.

Neste caso, para modelos de regressão linear, pode-se adotar (Draper e Smith, 1981) :

$$\text{Limites} = \hat{u} \pm t(v, 1 - \frac{1}{2} \alpha) s (1 + X_0^T P X_0)^{\frac{1}{2}}, \quad (2.15)$$

onde :

$t(v, 1 - \frac{1}{2} \alpha)$ = ordenada da distribuição t (de Student), com v graus de liberdade, correspondente ao limite de $(1 - \alpha) \%$ de probabilidade;

s = erro padrão amostral;

X_0 = observações individuais (registro) das variáveis explicativas;

$$P = (X^T X)^{-1};$$

Esta equação define o intervalo, em torno da previsão \hat{u} , o qual, com $(1-\alpha)\%$ de probabilidade, irá conter o valor u verdadeiro, correspondente à previsão realizada (\hat{u}). Os intervalos probabilísticos são consistentes, ou seja, serão maiores para valores extremos das variáveis explicativas, e menores para valores médios.

Portanto, intervalos de probabilidade atestam maior confiança nas faixas mais afastadas dos limites, em direção às médias magnitudes, mais freqüentes, uma vez que, além

dos limites tem-se extrapolações, sempre perigosas, e em suas proximidades a densidade amostral costuma ser menor, o que pode mais facilmente conduzir a erros de estimação.

Embora o potencial dos modelos empíricos lineares para apresentar previsões com probabilidade associada, sob forma de intervalos de confiança, seja uma qualidade reconhecida, observa-se que estes recursos são raramente utilizados. Na verdade, ocorrem dificuldades, na prática, quando estes intervalos são calculados para previsões fluviais.

Uma vez que os maiores intervalos, para um certo nível de probabilidade, ocorrem nos extremos, os quais inspiram menor confiança, ocorrem, muitas vezes, limites inferiores para os intervalos de confiança abaixo do que é possível, tendo-se em conta as curvas de recessão, as quais refletem o fenômeno do esvaziamento. Por vezes, chegam a ser calculados limites para os níveis d'água abaixo do leito do rio.

Por exemplo, na figura 2.1, o limite probabilístico inferior do intervalo de confiança δ , calculado em torno da previsão \hat{u} , encontra-se abaixo do valor mínimo (u_r), dado pela envoltória das recessões, e correspondente ao valor mínimo fisicamente realizável. Portanto, estes limites, nestes casos, não estão corretos, já que estabelecem, com uma probabilidade associada, um limite cuja ocorrência não é realmente possível.

Da mesma forma, os limites superiores, embora menos freqüentemente, podem extrapolar, em níveis altos, as possibilidades físicas, uma vez que o modelo não “sabe”, realmente, o funcionamento e os limites do sistema.




Figura 2.1 - Intervalos probabilísticos de confiança.

A adoção de modificações no limite inferior, para substituí-lo, quando for o caso, pela envoltória inferior de recessões, constituindo um limite “físico”, é uma possibilidade, tendo sido explorada por Fill e Mine (1989). Porém, corresponde à aceitação da inadequabilidade do limite probabilístico.

Embora a envoltória de recessões seja uma idéia interessante, de forma independente, quando usada conjuntamente com intervalos de confiança não chega a constituir-se em um

recurso integrado. Portanto, até então, a questão da previsão por intervalos, para o caso fluvial, constitui-se em um problema ainda não satisfatoriamente resolvido.

2.3. Os Sistemas Especialistas Difusos

2.3.1. Apresentação e Descrição

2.3.1.1. Introdução

As dificuldades da aplicabilidade da matemática aos problemas reais, uma vez que esta é tida como sinônimo de precisão, tem sido uma preocupação freqüente. Da mesma forma, a não-especificidade da linguagem tem sido considerada um defeito de expressão. Porém, é possível argumentar que esta não-especificidade transmite, muitas vezes, uma informação mais completa ou conveniente.

Por exemplo, pode-se transmitir dados sobre faixas do espectro eletromagnético correspondente a uma dada cor, em termos numéricos. Porém, sacrifica-se a importante sensação humana de cor, a qual é conseqüência de uma habilidade natural especial para agrupar e definir os agrupamentos. Portanto, de acordo com Mandani (1977), formas vagas de expressão podem representar aperfeiçoamentos os quais são fontes muito importantes de organização do conhecimento e, conseqüentemente, do pensamento criativo.

O desenvolvimento formal da lógica difusa (ou “fuzzy”) teve início em 1965, apresentado por Lotfi A. Zadeh, professor de ciência da computação na universidade da Califórnia, sendo basicamente uma teoria que permite a manipulação de conceitos abstratos, utilizados no vocabulário humano. O ponto de partida é a definição de valores intermediários entre avaliações convencionais tais como sim/não, verdadeiro/falso, branco/preto, sendo que cada categoria é representada por um conjunto difuso.

As noções da lógica difusa fornecem os recursos teóricos para a construção de uma ferramenta conceitual (sistema), com amplo leque de aplicabilidade, uma vez que termos vagos tais como “MEIO FRIO” ou “BAIXO” podem ser formulados e processados matematicamente. Desta forma, torna-se possível a aplicação de um meio semelhante ao humano de pensar, na programação de computadores. A lógica difusa constitui-se, portanto, num método para reproduzir a capacidade humana para o raciocínio aproximado e para julgamento em condições de incerteza.

Anderson(1983) apud Kosko (1992), sugere a utilização da lógica difusa para a previsão do tempo, onde existem graduações entre categorias lingüísticas sobrepostas. Por exemplo (figura 2.2), neblina densa (nd), chuvaisco (cv), chuva leve (cl) e chuva intensa (ci). O princípio básico da lógica difusa é que um elemento (x) pode pertencer, com menor ou maior grau ($\mu(x) = [0, 1]$), a mais de uma categoria.




Figura 2.2 - Categorias de tempo.

Claramente, a noção de conjunto difuso, representando ambigüidade em eventos, não coincide nem é conflitante com a noção de probabilidade de ocorrência destes eventos. São conceitos diferentes, os quais podem ser utilizados cooperativamente, de forma complementar.

Freqüentemente, necessita-se investigar a existência e a forma de relações funcionais, de causa e efeito ou de variação conjunta, entre as variáveis, nem sempre expressas com precisão numérica, de um sistema existente. Muitas vezes, a descoberta de uma relação pode conduzir à formulação de teorias para explicar os fenômenos observados, ou a desenvolvimentos para a utilização prática dos conhecimentos adquiridos.

A utilização dos recursos de origem probabilística depende da adoção prévia de uma relação funcional entre as variáveis numéricas, sob a forma de uma equação matemática. Existem técnicas (a análise de melhoria, na Regressão), para a orientação da experimentação em busca da formulação mais adequada. E, igualmente, para o ajuste dos parâmetros de cada formulação, como a técnica dos mínimos quadrados, por exemplo.

Sistemas especialistas tradicionais resultam do mapeamento do espaço do domínio no espaço das soluções, sendo o espaço do domínio constituído por condições ou estímulos, podendo ser uni ou multidimensional. O espaço das soluções, por sua vez, constitui-se em ações ou respostas.

A primeira etapa dos procedimentos para o projeto destes sistemas é a quantização do espaço amostral das variáveis, a qual consiste na divisão, em intervalos associados a

categorias, do universo de discurso das variáveis envolvidas. A seguir, a associação das categorias resultantes por meio de conjuntos de regras do tipo “SE ... ENTÃO ...”, constitui uma biblioteca específica de conhecimentos.

O conhecimento, então, é formado pelas ligações estabelecidas entre os intervalos do espaço do domínio e o espaço das soluções, ou seja, o espaço das variáveis independentes e o espaço da variável dependente, sendo estas ligações representadas pelas regras associativas.

O sistema obtido pode ser capaz de aproximar qualquer função implícita com qualquer grau de precisão desejado, dependendo apenas do detalhamento da categorização adotada (Kasabov, 1996). Porém, este pode ser inviabilizado se for necessário um grande número de regras para alcançar a precisão requerida.

Utilizando-se, por sua vez, conjuntos difusos parcialmente superpostos quando adjacentes, para representarem os intervalos quantizados, resulta em um sistema especialista difuso (ou “fuzzy”), governado pelas proposições lógicas representadas pelas regras da biblioteca de conhecimentos.

A lógica difusa, a qual tem contado com a contribuição de diversos autores para o seu desenvolvimento, fornece as ferramentas conceituais para a execução das operações sobre os conjuntos difusos e para a construção do sistema.

Pode-se demonstrar (Kosko, 1992) que um pequeno número de regras associativas, com escolha cuidadosa de conjuntos difusos para os intervalos no espaço do domínio de cada variável pode aproximar suficientemente qualquer função. Por esta razão, sistemas especialistas difusos são considerados aproximadores universais de funções.

Na figura 2.3, associações entre alguns dos respectivos conjuntos difusos triangulares, das variáveis x e y, fornecem uma aproximação da função representada, uma vez que valores intermediários resultam de interpolação.

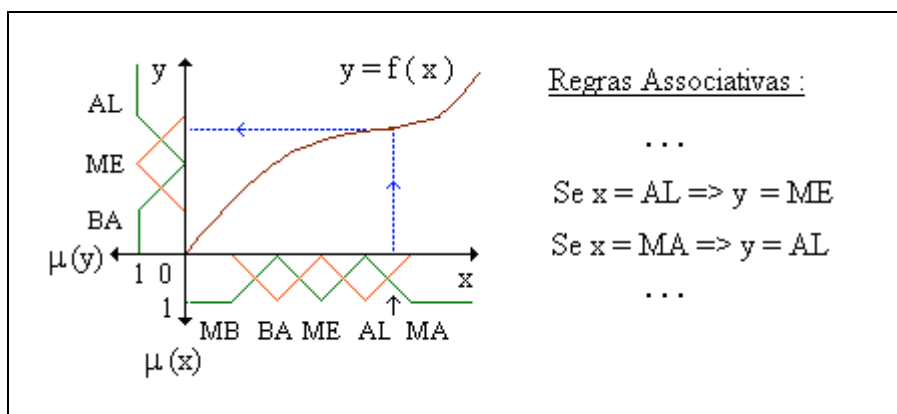


Figura 2.3 - Aproximação de funções.

Sistemas especialistas difusos podem ser considerados sistemas numéricos não-paramétricos, uma vez que conhecimento especialista (sob forma de regras) é usado para descrever ou acessar as relações associativas, expressas em linguagem natural (“SE .. ENTÃO .. “), entre os conjuntos. Tanto as entradas como as saídas correspondentes podem ser expressas numericamente. Também, podem ser definidas lingüisticamente, segundo terminologia adequada a cada caso, representando graus de intensidade.

Essencialmente, segundo Zadeh (1965), sistemas difusos constituem-se num meio natural para lidar com problemas nos quais a fonte de imprecisão é a ausência de critérios rigorosamente definidos para a pertinência de classes, mais do que a presença de variáveis aleatórias, uma vez que a noção de conjuntos difusos é de origem completamente determinística.

A investigação das possíveis relações, seja no estudo de fenômenos naturais, ou pesquisas de natureza laboratorial, econômica, social, etc., pode ser feita por meio da análise com métodos estatísticos, os quais são utilizados para verificar a variação conjunta ou ajustar modelos a partir de dados observados.

Entre as vantagens dos sistemas especialistas difusos em relação aos métodos estatísticos, tem-se : a capacidade de analisar e processar relações mais complexas (inclusive, não-paramétricas); não necessidade da adoção de fórmulas matemáticas hipotéticas a serem ajustadas para as investigações; a possibilidade de trabalhar com linguagem simbólica (quente, frio; verdadeiro, duvidoso, falso; etc.); e o fato de que, uma vez estabelecida a biblioteca específica de conhecimentos (caracterizada pelos conjuntos adotados para representar o domínio de cada variável e pelas regras associativas), ficam completamente delimitados o domínio e a imagem das relações.

As características principais da arquitetura de um sistema especialista (Kasabov, 1996) são, principalmente, a existência de uma biblioteca de conhecimentos (formada pela descrição da quantização adotada e pelas regras associativas), dos acessos aos dados, dos mecanismos de operação, das interfaces com o usuário, e dos recursos para a aquisição de conhecimentos ou o aprendizado automático a partir de amostras.

2.3.1.2. Fundamentos Teóricos

Em conjuntos clássicos, a pertinência ou não a um conjunto é bem definida, uma vez que estes possuem fronteiras rigorosas. Assim, por exemplo, um carro pode ou não estar em

uma determinada vaga, no estacionamento. Na prática, porém, as pertinências ou não pertinências, de forma absoluta (1 ou 0) não esgotam todas as possibilidades.

Para um conjunto difuso, existem graus intermediários de pertinência, uma vez que elementos podem pertencer a mais de um conjunto, competitivo ou adjacente, do mesmo universo de discurso. A pertinência de um elemento a um conjunto difuso, portanto, pode ser quantificada por uma função, chamada função de pertinência. Esta função descreve ambigüidade ou imprecisão, formas de incerteza diferentes de probabilidade, e muito comuns em situações reais.

Seja um universo de discurso X , compreendendo o domínio admitido para uma variável x . Pode-se definir um conjunto difuso J como sendo um intervalo de X ao qual é associada uma função de pertinência $\mu_J(x)$, que representa o grau com que x pertence a J , e cujos valores podem variar de 0 a 1. Por exemplo, na figura 2.4, $\mu_J(x)$ (função de pertinência de x ao conjunto J) representa o grau com que x pertence ao conjunto das pessoas jovens.




Figura 2.4 - Conjunto das pessoas jovens.

Ou seja, idade menor ou igual a 20 anos, neste modelo, é considerado jovem ($\mu_J(x) = 1$). Entre 20 e 30 anos, pode ser aceito como jovem com um certo grau de pertinência. Acima de 30 anos, o indivíduo não pertence ao grupo dos jovens ($\mu_J(x) = 0$).

Considerando-se X o universo de discurso (ou seja, o domínio da variável quantizada x), e J um conjunto difuso, pode-se individualizá-lo pelo par $(x, \mu_J(x))$, resultando na notação $\{(x, \mu_J(x)) / x \in X\}$.

Funções de pertinência caracterizam ambigüidade em um conjunto difuso, sendo conveniente sua apresentação e interpretação em forma gráfica. Não existem ainda recursos para a orientação quanto à forma a ser adotada, tendo-se em conta que, teoricamente, as possibilidades são ilimitadas, e que a forma “ideal” dependeria da natureza do problema e das variáveis envolvidas.

Alguns tipos padrões para as formas das funções de pertinência têm sido utilizados (Kasabov, 1996), sendo que o mais comum é o triangular, seguido do trapezoidal e do

sigmóide (figura 2.5). A escolha entre estes é consequência de preferência pessoal, existência de recursos computacionais ou experimentação em busca de resultados mais favoráveis.




Figura 2.5 - Funções de pertinência : Tipos padrões.

As formas adotadas para as funções de pertinência aos conjuntos difusos são, geralmente, convexas e normais. Um conjunto normal caracteriza-se por possuir pelo menos um elemento com grau de pertinência máximo igual a 1. Um conjunto convexo é formado por uma função de pertinência estritamente crescente, ou decrescente, ou crescente e após decrescente, correspondente a elementos positivamente ordenados do universo de discurso. No entanto, muitas operações sobre conjuntos difusos resultam em conjuntos que não atendem estas características.

A partir destes conceitos, pode-se conceituar números difusos, os quais consistem (Ross, 1995) em conjuntos difusos convexas e normais, com apenas um elemento com pertinência 1, e definido no conjunto dos números reais.

Um número difuso, portanto, é uma forma aproximada de apresentação e interpretação de números reais (figura 2.6), podendo ser manipulados algebricamente. Mais importante, porém, para sistemas especialistas, são as operações entre conjuntos difusos, as quais são diferentes das operações entre conjuntos clássicos.




Figura 2.6 - Número difuso “em torno de 12”.

Ross (1995) define o núcleo, o suporte e os limites das funções de pertinência, para conjuntos normais. O suporte de um conjunto difuso é a região com grau de pertinência maior do que zero ($\mu_J(x) > 0$). O suporte divide-se no núcleo, o qual caracteriza-se pela ocorrência de pertinência completa (grau unitário), e em um ou dois limites, os quais são regiões com grau de pertinência intermediário (entre 0 e 1).

Quando um único valor da variável representada possui grau unitário, este valor é chamado de protótipo do conjunto difuso. Os elementos descritos são as características dos conjuntos difusos, sendo ilustradas na figura 2.7.

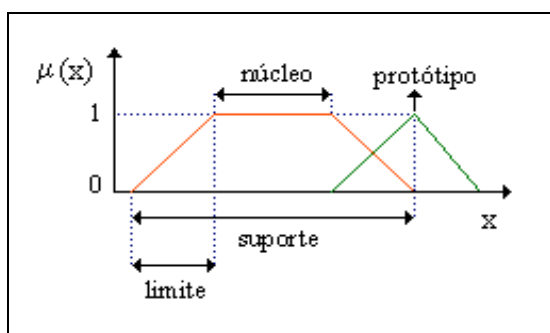


Figura 2.7 - Características dos conjuntos difusos.

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 tem sido utilizados.

A forma precisa dos conjuntos difusos não tem se revelado mais importante, na prática, do que sua localização no universo de discurso, o número de partições utilizadas, e a superposição adotada.

Teoricamente, a quantização difusa, quando esta é adotada corretamente, não deve conduzir à perda de informação, como ocorre com a discretização convencional. Kosko (1992) recomenda, com base na experiência, o uso de superposição de 25% entre conjuntos adjacentes (figura 2.8).

Excesso de superposição reduz a relevância dos conjuntos e torna imprecisa a atribuição a estes. Por outro lado, superposição reduzida tende para a bivalência (conjuntos não-difusos). Portanto, a recomendação do autor resulta da busca de equilíbrio para evitar situações extremas.




Figura 2.8 - Superposição de conjuntos difusos.

As operações mais comuns entre dois conjuntos difusos A e B, definidos no mesmo universo de discurso X (Kasabov, 1996), podem ser descritas para todo $x \in X$, e considerando-se $\mu_A(x)$ = grau de pertinência de x ao conjunto A, e $\mu_B(x)$ = grau de pertinência de x ao conjunto B, como :

- União ($A \cup B$) : $\mu_{A \cup B}(x) = \text{MAX}(\mu_A(x), \mu_B(x))$
- Interseção ($A \cap B$) : $\mu_{A \cap B}(x) = \text{MIN}(\mu_A(x), \mu_B(x))$
- Complemento ($\neg A$) : $\mu_{\neg A}(x) = 1 - \mu_A(x)$

As duas primeiras operações são ilustradas a partir da figura 2.9, na qual são representados os conjuntos difusos A (“em torno de 4”) e B (“entre 5 e 8”).




Figura 2.9 - Conjuntos triangular e trapezoidal.

Como consequência tem-se, na figura 2.10, os conjuntos resultantes das operações A e B, e $A \cup B$, respectivamente as operações de interseção e de união.




Figura 2.10 - Operações de Interseção e de União.

2.3.1.3. Procedimentos Funcionais

A construção e operacionalização de um sistema especialista difuso, para determinada aplicação, constitui-se na integração ordenada de diversos procedimentos, desde a quantização do espaço de domínio das variáveis até a desquantização das categorias resultantes, se for necessária uma resposta numérica.

A conceitualização consiste na atribuição de termos lingüísticos aos conjuntos difusos nos quais é quantizado o universo de discurso da variável. Então, este universo passa a constituir uma variável lingüística, a qual pode ser quantitativa (temperatura : ALTA, BAIXA; tempo : CEDO, TARDE), ou qualitativa (VERDADEIRO, INCERTO, FALSO).

Variáveis lingüísticas são, portanto, conjuntos de elementos simbólicos, sob a forma de conceitos, usados para descrever conhecimento. A cada conceito está associado um significado, na forma de um conjunto difuso.

O processo de dividir uma variável em um número conveniente de categorias, identificando e conceitualizando os conjuntos difusos resultantes, chama-se quantização difusa. Um exemplo é a representação de uma variável real por números difusos.

O procedimento de quantização difusa exige, além da decisão quanto ao número de categorias, a escolha da forma para as funções de pertinência para cada conjunto, bem como suas posições relativas.

As duas primeiras questões têm obtido soluções diferentes, para cada problema, dependendo da natureza destes, das variáveis envolvidas, da experiência e dos recursos disponíveis. A experimentação para a escolha de uma configuração aceitável é desejável. A sugestão da utilização de uma superposição de 25% (Kosko, 1992) pode ser uma referência, para a questão da posição relativa de cada conjunto.

Um nível maior de quantização difusa do domínio de cada variável pode resultar em um mapeamento mais detalhado das relações, porém, com risco de haver um número excessivo de regras associativas. Na prática, comprova-se que um número pequeno de conjuntos difusos para cada variável (sete, por exemplo), costuma ser suficiente, e possibilita a associação de expressões lingüísticas usuais aos agrupamentos, tais como “MÉDIO”, “BAIXO”, etc..

Os métodos, de natureza intuitiva, utilizados para associar conjuntos difusos com suas respectivas funções de pertinência aos conceitos de variáveis lingüísticas podem ser descritos por duas situações distintas (Ross, 1995) :

1. O intervalo que compõe o universo de discurso é conhecido. Neste caso, o intervalo é particionado, adotando-se, por exemplo, conjuntos difusos com suporte de mesma extensão. Porém, uma alternativa interessante é a partição diferenciada do domínio, baseada em critérios que premiam com maior detalhe certas regiões, em detrimento de outras. Por exemplo, pode-se detalhar mais fortemente regiões de maior frequência de ocorrência de dados amostrais, e menos fortemente regiões extremas. As categorias lingüísticas são atribuídas em função da posição relativa de cada conjunto, e do número de conjuntos.
2. Um observador experiente do fenômeno define os valores dos pontos típicos ou dos intervalos típicos, associados às categorias lingüísticas que os descrevem, com base no conhecimento especializado e nas necessidades existentes.

Então, atribui-se grau de pertinência unitário aos pontos centrais de cada partição e aos pontos extremos das partições extremas. A estes pontos é atribuído grau zero nos conjuntos difusos adjacentes, ficando os pontos intermediários na dependência da forma adotada para a função de pertinência.

As sentenças condicionais, do tipo SE <condições> ENTÃO <conseqüências>, as quais são recursos típicos da lógica clássica, constituem-se em meios bastante comuns para representar conhecimento humano, em sistemas especialistas. A lógica difusa é uma extensão da lógica clássica, onde as condições, bem como as conseqüências, são representadas por estruturas formadas pelos conjuntos difusos, possuindo, portanto, limites imprecisos.

Estas sentenças condicionais, ou relações de implicação, passam a constituir regras difusas, onde os antecedentes são uma ou mais declarações relativas a conjuntos difusos das variáveis quantizadas de entrada, e o conseqüente é uma declaração relativa a um conjunto difuso na variável de saída.

Cada declaração diz respeito à posição de uma variável em relação a um conjunto difuso definido, portanto, possui um grau de pertinência associado. Quanto maior o grau de cumprimento dos antecedentes de uma regra (ou seja, os graus de pertinência aos conjuntos envolvidos), maior a influência da declaração conseqüente desta regra sobre a resposta final. Esta influência é representada pelo grau de pertinência que é atribuído ao conjunto conseqüente desta regra, o qual pode ser chamado de grau de atribuição ou grau de acionamento (Gac).

Um valor numérico de entrada determina um grau de pertinência correspondente em cada conjunto difuso do universo de discurso, conforme este valor não pertença (grau 0), ou apresente pertinência total (grau 1) ou parcial (grau intermediário, entre 0 e 1), ao conjunto.

A operação de uma regra parte da determinação do grau de pertinência a cada um dos conjuntos difusos antecedentes. No caso de haver somente uma variável explicativa, o grau de acionamento é o grau de pertinência ao conjunto antecedente referenciado pela regra.

Caso haja mais de uma variável explicativa cujos conjuntos são relacionados por operações conjuntivas (\cap) ou disjuntivas (\cup), o grau de acionamento é consequência da operação correspondente (\cap : min; \cup : max), porém entre diferentes universos de discurso (figura 2.11). Na prática (Kasabov, 1996), uma regra com o operador \cup (max) pode ser substituída por regras que associam cada um dos antecedentes, independentemente, ao conseqüente.

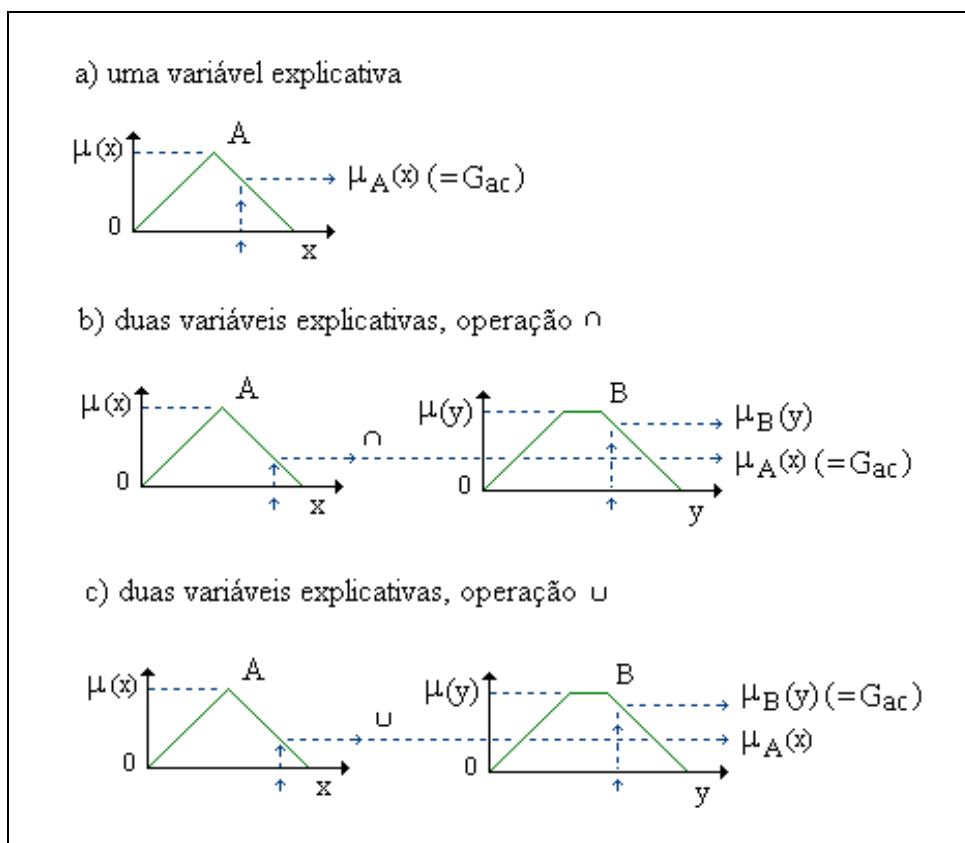


Figura 2.11 - Determinação do grau de acionamento.

Dois métodos são usualmente utilizados para, a partir do grau de acionamento, atribuir-se o grau da função de pertinência ao conjunto conseqüente de cada regra. Estes são, respectivamente, os métodos do mínimo e do produto.

O método do mínimo consiste no truncamento do conjunto conseqüente, segundo o grau de acionamento obtido no(s) conjuntos(s) antecedente(s), enquanto que o método do produto consiste na multiplicação do grau de acionamento pelas coordenadas dos pontos que definem o conjunto conseqüente (figura 2.12).

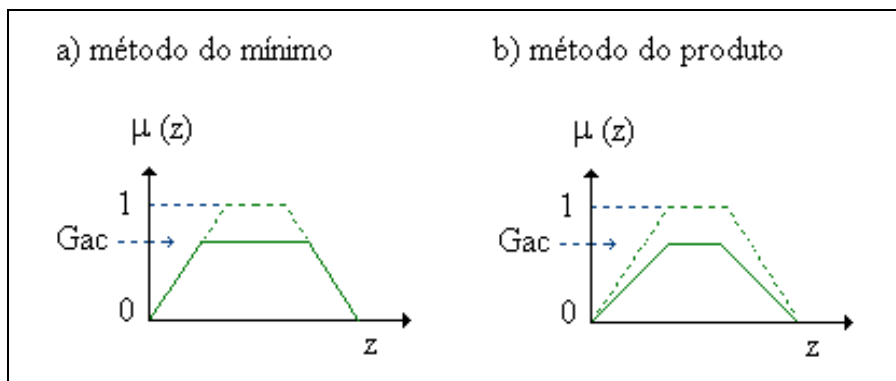


Figura 2.12 - Funções de pertinência ao conjunto resultante.

Sistemas constituídos por regras associativas resultam na utilização, em paralelo, de mais de uma regra, cujos resultados são agregados para que atinja-se a conclusão final, a partir das contribuições geradas pela expressão conseqüente resultante de cada uma destas regras.

O conjunto das regras difusas reproduz, então, o mapeamento do espaço das entradas no espaço das saídas do sistema. É bastante comum que um conjunto conseqüente seja referenciado por mais de uma regra, havendo necessidade de uma regra de composição para a obtenção da função de pertinência resultante.

A regra de composição mais utilizada tem sido a do máximo, a qual consiste na adoção da envoltória superior das funções de pertinência resultantes da aplicação de cada regra associativa.

Esta técnica de composição, quando combinada com regras que associam conjuntos de diferentes variáveis pela operação conjuntiva (\cap), resulta no procedimento mais clássico de sistemas difusos.

Porém, Kosko (1992) observa que, à medida que aumenta o número de regras do sistema, tende a ocorrer um achatamento da função de pertinência resultante, uma vez que uma única ocorrência pode tornar um conjunto tão ou mais importante quanto outro, mais freqüente.

Assim, mesmo que as regras 1, 2 e 3 tenham como conseqüente o conjunto A no universo de discurso da variável z, uma conseqüência da regra 4, indicando o conjunto C pode

alterar significativamente a conclusão final (figura 2.13). A alternativa sugerida é a técnica da composição aditiva, pela soma das funções de pertinência.




Figura 2.13 - Método clássico de composição.

O autor salienta que um grande número de regras resultam uma função de pertinência que tende a ser simétrica e unimodal quando a técnica de composição aditiva é utilizada, tendendo para uma distribuição gaussiana. Embora resultem picos maiores do que 1, a normalização é desnecessária, uma vez que esta não tem efeito sobre a singularização (ou desquantização), para a obtenção de uma resposta numérica.

A técnica de composição do máximo, por sua vez, resulta uma envoltória para a função de pertinência, a qual assemelha-se a dunas de areia tendendo ao achatamento à medida que aumenta o número de dunas cujo pico máximo é 1. Os dois procedimentos são ilustrados na figura 2.14.




Figura 2.14 - Comparação das técnicas de composição.

Os conjuntos difusos resultantes já exprimem, naturalmente, as incertezas associadas. Uma resposta numérica tem sentido, podendo constituir-se em uma aproximação válida, quando a função de pertinência composta destes conjuntos resulta unimodal.

Diversos procedimentos, de desquantização (ou singularização), têm sido propostos para obter-se as saídas numéricas (z) do sistema. Driankov (1996) sugere alguns critérios para

a escolha do método, entre os quais a continuidade, a plausibilidade, a desambigüidade e a complexidade computacional.

O critério da continuidade é atendido quando uma pequena alteração na entrada não implica em modificações sensíveis na saída. A plausibilidade ocorre quando o valor calculado situa-se aproximadamente no meio do domínio e possui um grau de pertinência elevado. Situações ambíguas conduzem a decisões duvidosas ou erradas, e a complexidade computacional, além de implicar em dificuldades indesejadas, pode retardar excessivamente o processamento.

Alguns métodos para a desquantização, descritos na figura 2.15, entre os mais usados, são avaliados pelo autor com base nestes critérios.

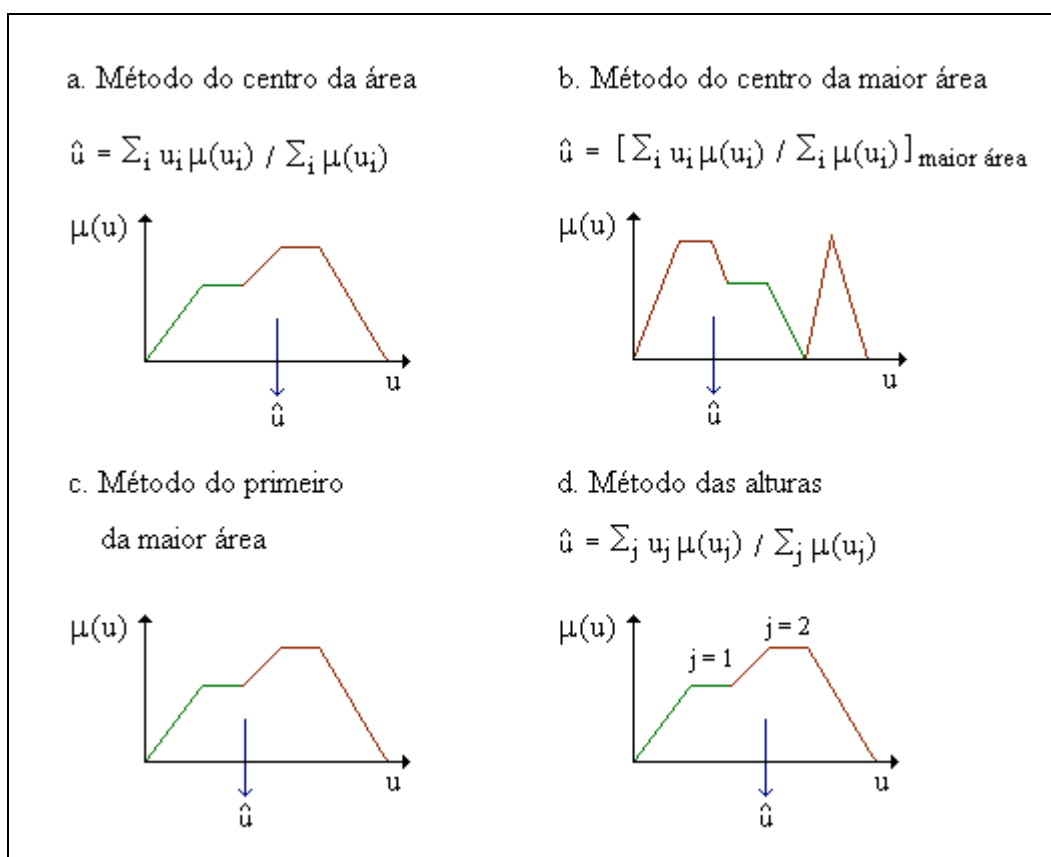


Figura 2.15 - Alguns métodos para desquantização.

O método mais comum é o do centro de gravidade (ou centro de área), cuja única crítica relevante é quanto à relativa complexidade computacional. O método do centro da maior área é plausível, mas pode falhar quanto aos demais critérios, especialmente a desambigüidade, o que não ocorre, por exemplo, com o método do primeiro da maior área,

cujas falhas principais são a plausibilidade e a continuidade. O método das alturas é adequado segundo todos os critérios considerados.

Com o objetivo de estabelecer-se ponderação diferenciada para as regras, diversos autores, entre eles Kosko (1992) e Kasabov (1996), recomendam a adoção de fatores de confiança para estas, sob a forma de pesos, com valores entre 0 e 1. Na prática, é possível que estes pesos alterem os resultados, na medida em que afetam as razões de interpolação entre os protótipos dos conjuntos adjacentes.

Portanto, estes fatores podem merecer um ajuste cuidadoso, uma vez que contribuem para a precisão da representação. No caso de uma função unívoca, o ajuste do fator de confiança equivale a um ajuste das magnitudes das funções de pertinência correspondentes.

O processo para obter-se a solução, para uma determinada situação (representada pelos dados), com base nos conhecimentos existentes (representados pelas regras) chama-se inferência. A descrição deste processo, considerando-se entradas e saídas numéricas, pode ser útil para a ilustração do funcionamento do sistema, conforme a figura 2.16, onde descreve-se um sistema que mapeia o universo de discurso Z em função dos universos X e Y.

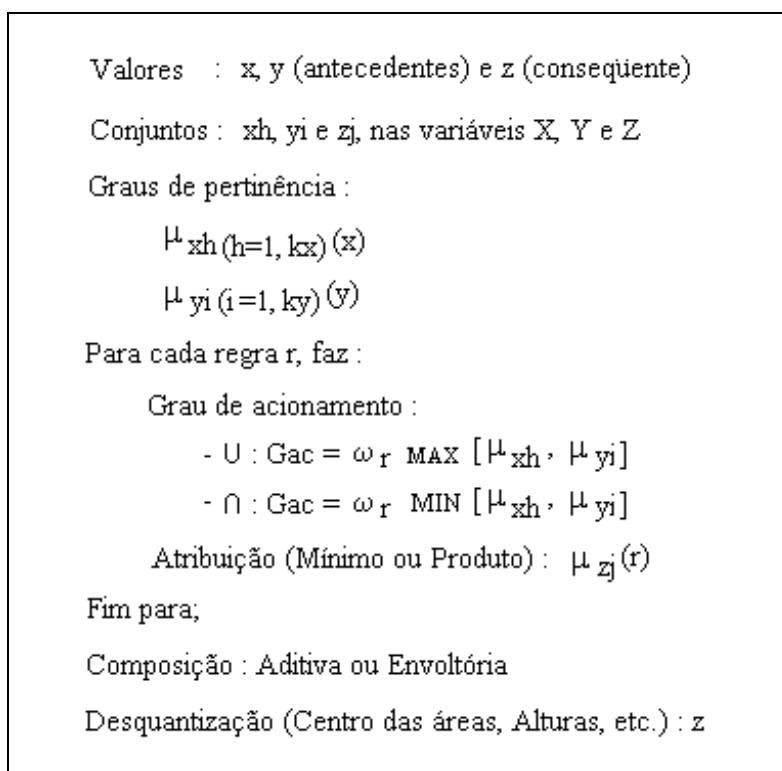


Figura 2.16 - Inferência em sistemas difusos.

As entradas do sistema são os valores do vetor V (x e y), onde x e y são valores numéricos. Os universos de discurso X, Y e Z são quantizados, respectivamente, nos

conjuntos difusos X_h ($h = 1, k_x$), Y_i ($i = 1, k_y$), e Z_j ($j = 1, k_z$), onde k_x , k_y e k_z são o número máximo de conjuntos utilizados.

Portanto, para cada vetor de entrada $V(x, y)$, são calculados os graus de pertinência aos conjuntos difusos em X e Y . Cada valor pode pertencer, ou a um conjunto difuso com grau de pertinência 1, ou a dois conjuntos difusos adjacentes, cujos graus de pertinência somam 1.

A seguir, todas as regras são acionadas (em paralelo), resultando cada regra r em um conjunto difuso de Z , com o grau de pertinência correspondente ($\mu_{z_j}(z)$), cujo valor dependerá da natureza das operações (\cup , \cap , etc.) correspondentes a cada regra associativa. Sendo m regras, resultam m conjuntos obtidos, geralmente em número maior do que k_z , uma vez que muitos podem ser referenciados por mais de uma regra, dependendo da relação existente.

Conforme o grau de importância de cada regra, são atribuídos pesos ($\omega_1, \dots, \omega_m$), a cada resultado individual e, através de uma regra de composição, obtém-se os graus de pertinência finais $\mu_{z_j(j=1, k_z)}(z)$, em Z .

Finalmente, pode-se, por meio de um processo específico de desquantização, obter-se o valor numérico z , ou então, pela análise dos graus de pertinência, o conjunto difuso mais representativo em Z (Z_j), conforme a natureza da resposta desejada.

Ross (1995) classifica os sistemas difusos em função da natureza das entradas e da saída do sistema. As entradas podem ser formadas por números, intervalos ou conjuntos difusos. As saídas podem ser números (mediante os processos de desquantização), conjuntos difusos ou funções matemáticas (lineares ou não-lineares). O modelo mais geral é caracterizado por entradas e saídas na forma de conjuntos difusos.

O número máximo de regras que podem ser utilizadas em um sistema, considerando-se n variáveis explicativas (ou universos de discurso), cada um constituído de k partições, é dado por $N_r = k^n$, ou, $N_r = (k + 1)^n$, caso seja considerada a proposição de não pertinência a nenhuma partição. No caso de adotar-se, para de cada variável, número diferente de partições (k_1, \dots, k_n), resulta $N_r = k_1 \cdot k_2 \cdot \dots \cdot k_n$.

Felizmente, o número necessário de regras é bem menor, devido às justaposições de conjuntos difusos adjacentes, responsáveis pelas capacidades interpolativas do sistema, e também porque muitos fenômenos tem suas possíveis realizações limitadas a regiões parciais do universo quantizado das variáveis. A dimensionalidade do sistema pode gerar dois tipos importantes de problemas :

- O primeiro é relativo à alocação de memória, sendo portanto um problema físico, decorrente das limitações dos recursos tecnológicos utilizados.
- O segundo problema diz respeito à existência de conhecimento suficiente dos fenômenos envolvidos, com o detalhamento exigido, para a formação das regras associativas que o sistema necessita.

A primeira dificuldade pode ser contornada, ganhando-se espaço às custas do tempo de processamento, pelo particionamento em estruturas convenientes, e mesmo pelo uso de memória física. A segunda é mais sutil, podendo inviabilizar muitas aplicações. Em casos nos quais necessita-se adquirir conhecimento sob forma de regras associativas a partir de amostras, pode ocorrer que não existam observações abrangentes dos fenômenos, para aquisição de conhecimento suficiente.

Portanto, é importante que as técnicas de aprendizado, utilizadas para a aquisição de conhecimento a partir das séries de observações realizadas, sejam capazes da extração do máximo possível de regras associativas a partir destas amostras, além de serem suficientemente robustas para suportar possíveis erros ou imprecisões de amostragem.

2.3.2. Técnicas de Aprendizado

Geralmente, sistemas difusos funcionam bem quando pode-se empregar experiência ou introspecção para estabelecer a quantização dos universos de discurso, atribuir os conceitos lingüísticos apropriados, escolher as funções de pertinência adequadas para os conjuntos difusos, bem como articular convenientemente as regras. Com frequência, porém, torna-se necessário o uso de técnicas desenvolvidas ou ajustadas para executar algumas destas tarefas, as quais constituem o aprendizado do sistema.

O uso de procedimentos automáticos para gerar regras a partir de amostragem, devido às dificuldades para domínio do conhecimento, é, muitas vezes, necessário, mesmo em sistemas apenas moderadamente complexos.

Neste caso, é importante a existência de amostragem suficientemente grande e representativa, para que seja possível a geração de um número mínimo de regras associativas, capazes de gerarem as respostas, e com a precisão desejada. Esta capacidade, chamada de habilidade para a generalização do modelo, deve ser verificada com outra amostra.

Os mecanismos de aprendizado dos sistemas a partir de dados amostrais, segundo Driankov (1996), são classificados em Adaptativos (ajuste dos pesos atribuídos às regras, ou

das funções de pertinência aos conjuntos difusos) e Organizativos (estabelecimento das regras associativas).

O aprendizado Organizativo é possível quando dispõe-se de amostragens, simbólicas, numéricas ou mistas, das variáveis que sabe-se estarem relacionadas, mas desconhece-se estas relações, seja parcialmente seja em sua totalidade. Então, técnicas de agrupamento, após a categorização difusa do universo de discurso de cada variável, podem produzir a descrição das relações existentes, sob forma de regras associativas.

O aprendizado Adaptativo é necessário quando o comportamento relativo entre as variáveis relacionadas, o qual pode ser expresso sob forma de regras associativas, é conhecido, porém apenas nos seus aspectos qualitativos. A aplicação prática deste conhecimento depende de encontrar-se o número e a posição dos conjuntos difusos, representados por ordens de intensidade no universo de discurso de cada variável, bem como a forma respectiva de cada função de pertinência.

Em sistemas difusos variáveis com o tempo as regras (sistemas Auto-Organizativos), ou os parâmetros do sistema (sistemas Auto-Adaptativos), são modificados à medida que o mesmo executa a amostragem e processa os dados. Neste caso, pode-se partir de uma configuração aproximada, uma vez que, espera-se, o próprio sistema convirja para a configuração ideal, ou mesmo adapte-se às alterações do processo representado, se for o caso.

Entre as ferramentas tecnológicas que tem sido utilizadas para o ajuste da configuração do sistema, ou aprendizado, a partir de amostras numéricas, citam-se os algoritmos genéticos e as redes neurais, principalmente. Estas ferramentas tem constituído recursos técnicos importantes, para pesquisa de agrupamentos, parâmetros e configurações dos sistemas, embora sem produzir acréscimos à teoria. Da mesma forma, algoritmos específicos de aprendizado tem sido utilizados, tanto para sistemas Organizativos quanto Adaptativos.

Grandes alterações nos conjuntos difusos podem destruir a significância das variáveis lingüísticas, o que, em muitos casos, é indesejável. Por outro lado, pequenas alterações em tão grande número de parâmetros são inócuas. Portanto, Mandani (1977), considera mais compensadora a dedicação de esforços ao aprendizado e à formulação das regras associativas.

A idéia básica dos sistemas Organizativos é a pesquisa dos agrupamentos dos dados amostrais, ou em células formadas pelas combinações dos intervalos pré-definidos correspondentes aos conjuntos difusos (figura 2.17), ou em torno de centróides resultantes das combinações dos protótipos dos conjuntos difusos das diferentes variáveis.




Figura 2.17 - Pesquisa de regras por análise de agrupamentos.

Portanto, os sistemas Organizativos difusos, geralmente, compõe-se de duas fases principais, as quais são :

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

O método apresentado por Kosko (1992), utiliza algoritmos Adaptativos de agrupamento para a estimação da regra associativa a partir dos dados da amostra disponível para o aprendizado. A repartição do espaço amostral das variáveis é o ponto de partida para a combinação dos conjuntos difusos em células multidimensionais.

A contagem de ocorrências em cada célula resulta num histograma de frequências nas células da variável explicada, em função do qual é extraído o conseqüente e são estabelecidos os pesos para cada regra. Por exemplo, para os antecedentes X e Y, na figura 2.18, procura-se a regra correspondente para a ocorrência dos conjuntos (categorias) ME e BA, respectivamente.

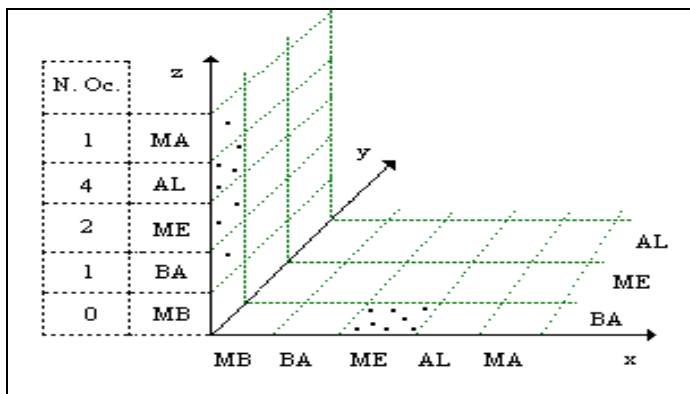


Figura 2.18 - Determinação do conseqüente da regra associativa.

Observa-se no exemplo que, dos oito (8) pontos amostrais com os antecedentes considerados (em X e Y), a concentração máxima, na variável conseqüente, corresponde à categoria AL. Portanto, a regra pesquisada para os antecedentes ME e BA em X e Y é o conseqüente AL em Z (ME, BA; AL).

O autor representa o conjunto de regras associativas sob forma de uma matriz multidimensional, onde cada dimensão corresponde a uma variável explicativa, devidamente quantizada, e os elementos são os conjuntos conseqüentes na variável explicada.

O conhecimento representado nesta forma, chamada FAM (“Fuzzy Associative Memory”) pode ser convertido para a forma de regras associativas, e vice-versa.

Na figura 2.19, tem-se a representação do conhecimento correspondente a um sistema com duas variáveis explicativas (x e y) e uma variável explicada (z), quantizadas segundo os símbolos MB (muito baixo), BA (baixo), ME (médio), AL (alto) e MA (muito alto).

A abrangência do espaço amostral nem sempre é suficiente para cobrir adequadamente as necessidades para o ajuste e uso do sistema, o que exige a interferência do especialista para definir as regras extremas e seus pesos, independentemente das freqüências de ocorrência. Portanto, é muito raro que o aprendizado de um sistema possa ser perfeitamente realizado com base unicamente em dados amostrais.

$y \backslash x$	MB	BA	ME	AL	MA
AL			MA	MA	MA
ME		ME	AL		
BA	BA				

Figura 2.19 - FAM : “Fuzzy Associative Memories”.

A representação da FAM por meio de regras associativas resulta :

SE $x = MB$ e $y = BA$ ENTÃO $z = BA$;

SE $x = BA$ e $y = ME$ ENTÃO $z = ME$;

SE $x = ME$ e $y = ME$ ENTÃO $z = AL$;

SE $x = ME$ e $y = AL$ ENTÃO $z = MA$;

SE $x = AL$ e $y = AL$ ENTÃO $z = MA$;

SE $x = MA$ e $y = AL$ ENTÃO $z = MA$;

Wang e Mendel (1992) propõe uma estratégia para combinar informações, tanto de origem numérica quanto lingüística. A idéia básica é gerar regras difusas a partir das séries numéricas amostrais, conjugar estas regras com aquelas provenientes do conhecimento especializado e, finalmente, projetar o sistema articulando-o na biblioteca combinada de regras associativas difusas.

O método sugerido para a pesquisa amostral é descrito, através do exemplo da figura 2.20, constituindo-se num procedimento Organizativo, onde a quantização dos universos de discurso e a adoção das respectivas funções de pertinência são ações preliminarmente executadas.

```

Amostragem :
    ( Xk , Yk ; Zk ) : Fck = Registro k
Definições :
    ( xh , yi ; zj ) : ωr = Regra Associativa
    xh = Conjunto mais favorecido em X
    ωr = Peso atribuído à regra
    μxh ( Xk ) = Pertinência de Xk em xh
Procedimento :
    Para cada registro, faz :
        Calcula μxh ( Xk ) , μyi ( Yk ) e μzj ( Zk )
        g = μxh ( Xk ) μyi ( Yk ) μzj ( Zk ) Fck
        Se  $\exists$  ( xh , yi ; zj ) : ωr Ou g > ωr Então faz :
            ωr = g ; Regra = ( xh , yi ; zj ) : ωr
        Fim se;
    Fim para;
Fim procedimento;

```

Figura 2.20 - Auto-organização amostral por registros.

Cada amostra individual k, ou registro amostral, é constituída de valores numéricos antecedentes (x e y) e conseqüente (z), além de um fator de confiança (Fc) associado.

Os graus de pertinência aos respectivos conjuntos, de cada valor, são calculados, sendo que a regra resultante é determinada pelo agrupamento dos conjuntos difusos que apresentam maior pertinência.

O grau atribuído a esta regra (ω_r) resulta do produto dos graus de pertinência de cada conjunto antecedente, multiplicado pelo grau de pertinência ao conjunto conseqüente, e por um fator de confiança (F_c), entre 0 e 1, atribuído a cada registro k da amostra.

Uma vez que cada registro gera uma regra, o grau atribuído a esta é importante para resolver conflitos, no caso de uma mesma configuração antecedente indicar diferentes conjuntos conseqüentes.

O método é utilizado pelos autores, com sucesso, para previsão de valores futuros de uma série temporal caótica gerada a partir de uma função matemática específica. Utiliza-se como variáveis explicativas o valor presente e os valores passados. A aplicação é muito semelhante ao uso de modelos autoregressivos para previsões de curto prazo.

Sudkamp e Hammell (1994) consideram que, neste método, a regra resultante pode ser afetada por dados errados ou perturbados, presentes na amostra de treinamento. Erro em apenas um registro amostral pode comprometer uma regra associativa, independentemente da precisão de todos os demais registros.

Além disso, observa-se que o aproveitamento de apenas parte da informação contida no registro, ou seja, apenas o conjunto mais favorecido em cada variável, pode ser inconveniente quando a amostra disponível é limitada (casos práticos), e é grande o número necessário de regras para domínio do conhecimento.

Uma terceira fase em procedimentos de aprendizado Organizativo é proposta por Sudkamp e Hammell (1994), consistindo no preenchimento dos vazios de conhecimento na representação matricial das regras associativas, com base em conceitos de interpolação e similaridade.

A representação da FAM é inicialmente modificada. Os rótulos dos antecedentes são substituídos pelos números correspondentes aos pontos centrais dos conjuntos difusos triangulares utilizados. Da mesma forma, os elementos da FAM, os quais representam os conseqüentes, passam a ser representados pelos números correspondentes. Na figura 2.21, apresenta-se um exemplo do caso bidimensional.

A hipótese básica do método é de que a similaridade de combinações de antecedentes deve produzir similaridade nos conseqüentes, e de que similaridade é equivalente a proximidade. Os dois métodos apresentados são os de expansão da região conhecida e o da média ponderada.

$y \backslash x$	10	30	50	70	90
-1			90	90	90
0		50	70		
1	10				

Figura 2.21 - FAM numericamente rotulada.

No primeiro método, são executadas diversas iterações, até que toda a matriz que representa conhecimentos esteja preenchida. Em cada iteração os elementos vazios são substituídos pela média dos valores dos elementos adjacentes.

Assim, para o sistema representado na figura 2.21, ao elemento de coordenadas (1, 30), seria atribuído o valor 30, enquanto que o elemento (-1, 30) ficaria com valor 70, e assim por diante.

O método seguinte, por sua vez, permite que todos os elementos não vazios contribuam, de forma ponderada pela proximidade, ao cálculo do elemento vazio.

Após o preenchimento desta matriz por um dos dois métodos, os elementos são substituídos pelo centro mais próximo dos conjuntos consequentes. A FAM é obtida como resultado da substituição da rotulação numérica pela simbólica.

Funções matemáticas contínuas são utilizadas para teste dos dois métodos, os quais conseguem melhorar os resultados da aplicação de sistemas inicialmente incompletos, gerados para representarem estas funções. As diferenças de desempenho dos dois procedimentos não são muito diferentes, tendendo as vantagens, ora para um, ora para outro.

Sabe-se que os sistemas especialistas difusos possuem, naturalmente, capacidades interpolativas, o que permite a operação, mesmo com uma certa degradação da biblioteca de conhecimentos (Kosko, 1992).

Quando é possível que a função apresente variações bruscas de comportamento, ou que esta não seja contínua em seu domínio, o preenchimento da FAM com base em similaridade e interpolação pode não proporcionar representação adequada do comportamento do sistema real que deseja-se reproduzir.

No artigo de Rojas et alii (2000) é apresentado um método Organizativo e Adaptativo para construir o sistema difuso a partir de dados numéricos. O método desenvolve-se em três fases.

Na primeira, são geradas, por um procedimento Organizativo, regras associativas para um sistema inicial, muito simples (com poucos conjuntos para cada variável).

A segunda fase é também adaptativa, uma vez que a topologia do sistema é alterada. Determina-se para qual variável, a cada iteração, é mais importante o incremento da quantização, e em que posição deve ser localizado o novo conjunto, refazendo-se a seguir o procedimento Organizativo.

Na terceira fase, é escolhido o melhor compromisso entre precisão e complexidade, uma vez que esta aumenta exponencialmente à medida que maior precisão é requerida.

O procedimento Organizativo utilizado analisa toda a amostra, para cada combinação possível de conjuntos antecedentes. Neste método, portanto, as regras são formadas diretamente, uma por vez.

No exemplo da figura 2.22, tem-se um sistema com duas variáveis explicativas (x e y) e uma variável explicada (z). x_h e y_i são, respectivamente, os conjuntos nos quais cada variável é quantizada. A variável explicada correspondente é determinada numericamente, sendo simbolizada por z_{hi} .

Amostragem :

$$(x_k, y_k, z_k) = \text{registro } k$$

Definições :

$$(x_h, y_i, z_{hi}) = \text{regra associativa}$$

x_h, y_i = conjuntos possíveis nos universos X e Y

z_{hi} = valor numérico de z, para conjuntos x_h e y_i

$$\mu_{x_h}(x_k) = \text{pertinência de } x_k \text{ em } x_h$$

Procedimento :

Para cada combinação possível $x_h \times y_i$, faz :

Para cada registro individual k, faz :

Calcula $\mu_{x_h}(x_k)$ e $\mu_{y_i}(y_k)$

$$\sum z\mu = \sum z\mu + z_k \mu_{x_h}(x_k) \mu_{y_i}(y_k)$$

$$\sum \mu = \sum \mu + \mu_{x_h}(x_k) \mu_{y_i}(y_k)$$

Fim para;

$$z_{hi} = \sum z\mu / \sum \mu$$

Fim para;

Figura 2.22 - Auto-organização amostral por regras.

A análise de toda a série amostral, para cada combinação possível de conjuntos antecedentes resulta em maior consumo de tempo, embora constitua-se em um algoritmo de fácil programação. Por outro lado, a análise é exaustiva, resultando no máximo de regras que é possível extrair de cada amostra, o que contribui para a redução da ocorrência de casos de “falta de conhecimento” durante a operação do sistema.

O método para a decisão do nível de complexidade desejada (número de conjuntos difusos de cada variável), em função da precisão, é um tanto subjetivo, uma vez que consiste na observação da relação entre o número de conjuntos difusos gerados e a função quadrática resultante da simulação, para diversos casos.

Uma vez que a função quadrática possui um comportamento exponencialmente decrescente com o aumento da complexidade, existe uma inflexão, a partir da qual aumentos relevantes no número de conjuntos difusos utilizados não resultam em melhorias significativas na qualidade. Este ponto de inflexão constitui-se, segundo os autores, no compromisso desejado.

Os métodos Organizativos baseados em agrupamentos são, muitas vezes, restritos pelas limitações da capacidade de alocação de memória, uma vez que o número de combinações possíveis aumenta exponencialmente com o número de partições utilizadas. Para cinco variáveis explicativas, com nove partições cada, resultam 59049 elementos na FAM gerada, o que pode representar dificuldade adicional de programação e alocação de memória.

O método utilizado por Wang e Mendel (1992) contorna o problema computacional, pela adoção da regra sugerida pelo registro que resulta em maior grau associado, porém incide em riscos caso os valores amostrais contenham erros, conforme Sudkamp e Hammell (1994).

O método de Rojas et alii (2000), analisa toda a amostra disponível, na investigação de cada possível regra, uma por vez, evitando a manipulação de grandes matrizes, porém o consumo de tempo pode ser muito grande.

Nos procedimentos de aprendizado utilizados pela maioria dos autores, o problema da quantidade de amostras disponíveis é irrelevante, pois os métodos são testados com séries resultantes de funções matemáticas.

No trabalho de Wang e Mendel (1992), séries temporais caóticas são geradas por equações não-lineares. Sudkamp e Hammell (1994) utilizam-se de diversas funções, porém perturbam as séries obtidas, para investigar a robustez dos procedimentos. Rojas et alii (2000), utilizam diversas equações matemáticas, porém determinísticas.

Portanto, ficam dúvidas quanto à aplicabilidade destes métodos para a análise de fenômenos reais, principalmente quanto ao aspecto da dimensionalidade, e quanto à

existência de amostragem suficiente, na aquisição de conhecimentos a partir de registros amostrais. Além disso, em situações práticas, pode ocorrer que as variáveis explicativas sejam qualitativas ou simbólicas, o que, sem dúvida, exige sofisticação adicional.

2.3.3. Previsões Aproximadas : Categorias

As respostas de um sistema baseado em lógica difusa são extraídas das configurações de conjuntos difusos e respectivos graus de pertinência resultantes da composição dos conseqüentes das regras associativas. A solução a ser adotada, deduzida a partir desta configuração, pode ser de duas naturezas, ou seja, sob forma de categorias ou sob a forma numérica, obtida por meio da operação de desquantização sobre estes conjuntos.

Embora seja mais específica, nem sempre a forma numérica é a mais conveniente para previsão, uma vez que raramente coincide com as observações posteriores, o que, com o tempo, pode comprometer a confiabilidade.

A determinação da categoria prevista, porém, não é imediata. É muito comum, no caso da composição envoltória, quando trabalha-se com grande número de regras, que diversos conjuntos apresentem os maiores graus de pertinência coincidentes ou muito próximos.

A freqüência destes casos é substancialmente reduzida, mas não eliminada, com o uso da composição aditiva. Portanto, o critério de adotar-se, simplesmente, o conjunto com maior grau agregado de pertinência pode não ser suficiente, havendo necessidade de considerações adicionais.

Uma alternativa conveniente, especialmente se as distribuições para as funções de pertinência dos conjuntos conseqüentes forem unimodais, é a adoção, como categoria prevista, do conjunto difuso ao qual pertence mais fortemente o resultado numérico obtido pela desquantização.

No caso de serem aproveitadas, para divulgação e tomada de decisões, também as previsões numéricas, este critério tem o mérito de evitar possíveis ambigüidades que venham a dificultar a interpretação.

As previsões categorizadas, uma vez viabilizadas, constituem-se na forma aproximada de previsões com sistemas especialistas, as quais, diferentemente de suas correspondentes nos modelos estocásticos, sob forma de intervalos probabilísticos em torno dos valores previstos, são constituídas de categorias previamente definidas.

Em previsões de níveis, estas categorias estão associadas a intervalos linimétricos, por exemplo, níveis “MÉDIOS”, “ALTOS”, ou “MUITO ALTOS”, os quais, por sua vez, definem

áreas de inundação correspondentes, podendo ser suficientemente úteis para a tomada de decisões, especialmente se as previsões forem confiáveis.

É desejável que, com o tempo, não apenas as autoridades responsáveis, mas também os cidadãos interessados, venham a acostumar-se com a previsão simbólica, atribuindo significado e condicionando-lhe suas decisões com respeito à segurança, com mais facilidade e confiança do que o fariam, se dispusessem apenas das previsões numéricas de níveis de inundações.

Assim, quando um morador ouve no rádio, por exemplo, que o nível do rio nas próximas horas estará “ALTO” ou “MUITO ALTO”, ele pode com mais facilidade associar estes conceitos à situação esperada para seu bairro, considerar os riscos existentes e agir ou não, de acordo com estes, com base em sua própria experiência ou em mapas de inundação e outros estudos prévios que tenham sido divulgados.

Pode-se associar, indiretamente, probabilidades às categorias previstas. Isto pode ser feito ajustando-se diversos modelos, com categorização progressivamente mais detalhada do universo de discurso da variável prevista.

Então, para amostras suficientemente representativas dos fenômenos com os quais pretende-se trabalhar, verifica-se, por meio de simulação, as probabilidades de acerto, para cada nível de quantização, adotando-se a categorização correspondente à probabilidade desejada.

Se é desejado, por exemplo, 95% de acerto, isto será obtido para uma categorização menos detalhada do que se o nível de acerto exigido for de 90%. Ou seja, hipoteticamente, talvez tenhamos que adotar 5 categorias apenas, para garantir 95% de acerto, uma vez que acertaríamos somente 90%, com sete categorias.

Sacrifica-se, pois, a precisão pela confiabilidade. Significa que, com os dados disponíveis e as técnicas utilizadas, tendo-se em conta a rapidez dos fenômenos e o tempo de alcance utilizado para as previsões, a confiabilidade estabelecida somente pode ser atendida para aquele nível de categorização.

As previsões, colocadas desta forma, são subjetivas. Porém podem auxiliar decisões e estabelecer níveis de prontidão e alerta de autoridades. Neste caso, a confiabilidade pode pesar mais do que a precisão de apresentação das respostas, nem sempre coincidente com as precisões com que pode-se realmente contar.

2.4. A Qualidade das Previsões

A análise visual dos erros de previsão pode, por si própria, fornecer informações importantes sobre os resultados obtidos, bem como constituir-se em um meio para escolha entre modelos competidores.

As desvantagens da abordagem visual são o dispêndio de tempo e a falta de objetividade, a qual pode produzir discordância entre diferentes analistas. Por estas razões, tem-se preferido o uso de coeficientes numéricos para a avaliação da qualidade das previsões.

Os testes para análise do desempenho dos modelos de previsão, portanto, são estatísticas com as quais procura-se verificar as precisões dos resultados obtidos, quando confrontados com as observações correspondentes de uma ou mais séries amostrais.

São utilizados com freqüência o Desvio Padrão dos Erros de Previsão, ou Erro Padrão de Previsão (E_p), o Erro Médio (E_m) e o Coeficiente de Eficiência (C_e) :

$$E_p = [1/k \sum_t (\hat{u}_t - u_t)^2]^{1/2} \quad (2.16)$$

$$E_m = 1/k \sum_t \|\hat{u}_t - u_t\| \quad (2.17)$$

$$C_e = 1 - \sum_t (\hat{u}_t - u_t)^2 / \sum_t (u_{\mu} - u_t)^2, \quad (2.18)$$

onde :

u_t = observação, no intervalo t , da variável a ser prevista;

u_{μ} = média dos valores amostrais de u ;

\hat{u}_t = valor previsto de u para o intervalo de tempo t ;

k = número de observações.

O Erro Padrão e o Erro Médio medem a dispersão das previsões em torno das observações. O Coeficiente de Eficiência, introduzido por Nash e Sutcliff (1970) apud Lanna e Indursky (1983), é a proporção com que o modelo explica a variância da variável observada.

Uma outra classe de testes para a qualidade dos resultados de modelos de previsão, é a que compara a qualidade das previsões do modelo com as que podem ser obtidas com um modelo alternativo. Inicialmente, tem-se o Coeficiente de Eficiência Relativa (E_r) entre dois modelos (Lanna e Indursky, 1983) :

$$E_r = 1 - \sum_t (\hat{u}_t - u_t)^2 / \sum_t (\hat{u}_{a_t} - u_t)^2, \quad (2.19)$$

o qual calcula a fração adicional da variância das observações que é explicada pelo modelo testado (previsões \hat{u}_t), além da variância explicada pelo modelo alternativo (previsões \hat{u}_a).

O Coeficiente de Eficiência (Ce), por sua vez, pode ser redefinido, a partir da noção do coeficiente de eficiência relativa, como o teste que compara a qualidade das previsões do modelo (\hat{u}_t) com a previsão sistemática da média (u_μ).

Um teste simplificado, porém de interesse, é obtido pelo Coeficiente de Persistência, o qual consiste no Coeficiente de Eficiência Relativa que compara o modelo proposto com o modelo que sistematicamente previria a variável como assumindo o valor observado no presente. Esta é a previsão sempre disponível tendo por base a suposição de que a situação presente persistirá.

Outra possibilidade de avaliar-se a qualidade das previsões, em modelos empíricos lineares, é pela magnitude do intervalo de confiança. Ou seja, grandes intervalos significam que a previsão merece menos confiabilidade, e vice-versa. Uma vez que o intervalo obtido faz parte da previsão, tem-se uma avaliação individual e antecipada da qualidade desta.

No caso de utilizar-se diversos modelos, para adotar-se as previsões dos que apresentam melhor desempenho para cada situação, pode-se utilizar os últimos intervalos fornecidos por cada um, para a tomada de decisão quanto ao modelo mais confiável.

Assim, em uma hipótese simplificada, pode ocorrer que em determinada situação, por exemplo, níveis altos com chuvas fracas, um modelo apresente-se melhor do que outro, que, por sua vez, apresenta melhor desempenho em situações de níveis médios e chuvas fortes. Neste caso, o modelo mais adequado revelar-se-á pela apresentação de um intervalo de probabilidade menor, atestando maior confiança no resultado.

No caso de modelos gerados pelo sistema especialista, pode-se usar, para as previsões pontuais, as mesmas estatísticas anteriores, inclusive intervalos de confiança probabilísticos, os quais podem ser gerados a partir da análise de resíduos resultantes de simulação sobre dados amostrais suficientemente grandes.

Porém, mais coerente com a metodologia destes modelos, é a utilização de índices que atestem a freqüência com que constata-se o acerto das previsões por categorias. Ou, alternativamente, orientem a pesquisa do número e, conseqüentemente, da amplitude dos conjuntos difusos necessários para que o modelo ajustado acerte as previsões nas categorias, com uma freqüência estabelecida previamente, considerada satisfatória.

3. Metodologia

3.1. Considerações Gerais

A verificação do potencial de sistemas especialistas com uso de lógica difusa, para previsões em tempo atual de níveis de inundação, constitui-se no principal objetivo dos testes realizados nesta pesquisa. Sendo estes sistemas aproximadores universais de funções, eles podem ser, em princípio, empregados para representar tanto efeitos de propagação de descargas quanto transformações hidrológicas das chuvas.

A modelagem com sistemas especialistas depende da categorização das variáveis, sendo as categorias representadas por expressões simbólicas, tais como ALTO, MÉDIO, BAIXO, etc. Espera-se que estas categorias tenham, de preferência, um significado compatível com a experiência sensível humana, uma vez que conta-se com a possibilidade de, em situações práticas, aproveitamento de respostas qualitativas, representando faixas de domínio da variável explicada, para tomada de decisões. Fazendo-se analogia com as previsões meteorológicas, busca-se respostas confiáveis, mesmo com o sacrifício da precisão.

Durante a realização desta pesquisa, foram constatados dois fenômenos extremos que ocorrem durante o aprendizado, os quais representam dificuldades a serem superadas. Estes fenômenos condicionaram alguns aspectos da aplicação da metodologia e exigiram aperfeiçoamentos nas técnicas utilizadas, sendo chamados, respectivamente, de “falta de conhecimento” e “falso conhecimento”.

A “falta de conhecimento” manifesta-se quando o aprendizado é insuficiente, ocorrendo, posteriormente, novas situações para as quais não existem regras. Para prevenir este caso, é utilizado, continuamente, o recurso, idealizado para esta pesquisa, das bibliotecas combinadas de conhecimento, as quais incorporam, quando necessário, as regras correspondentes aos modelos mais simples, submetidos previamente.

O “falso conhecimento”, por sua vez, ocorre quando o aprendizado conduz a conjuntos de regras que descrevem perfeitamente as séries submetidas, porém não necessariamente representam os fenômenos ou as relações subjacentes, o que prejudica a generalização do uso.

Algumas regras geradas, nestes casos, descrevem particularidades de causa desconhecida, ou de natureza aleatória, ou mesmo erros dos dados utilizados, podendo corromper os resultados quando o modelo formado pela biblioteca de conhecimentos é aplicado para previsão ou simulação.

Muitas vezes, regras associativas são geradas a partir de poucas ocorrências da combinação correspondente de antecedentes, ou mesmo de uma única ocorrência, que pode ser casual ou incorreta. Então, a regra obtida pode ou não ser significativa, para uso posterior, embora contribua claramente para a descrição da série submetida ao aprendizado.

Em um modelo com apenas três variáveis, quantizadas em nove categorias, por exemplo, resultam 729 conexões possíveis. O uso de um critério estatístico, com exigência de um mínimo de ocorrências de cada combinação, como condição para aceitar-se a regra associativa sugerida, seria desejável, porém inviabilizaria o uso, tendo-se em conta a exigüidade das amostras disponíveis para o aprendizado, em situações práticas.

Quanto maior a complexidade do modelo, maior a frequência de regras aprendidas a partir de poucas observações, ou mesmo observação única. Nestes casos, pode acontecer que as estatísticas dos modelos mais complexos sejam melhores, quando estes são aplicados às séries de aprendizado, porém sejam piores que as dos modelos mais simples, quando ambos são aplicados a outras séries.

Portanto, ao longo desta pesquisa, as comparações entre os resultados dos modelos investigados, ou mesmo a seleção das componentes com as quais o modelo apresenta melhor desempenho, são executadas, principalmente, pela análise do comportamento destes quando utilizados para simulação com séries diferentes das que foram empregadas no aprendizado.

Uma vez que o uso de sistemas especialistas com lógica difusa constitui-se em uma nova alternativa para a previsão em tempo atual, é esperado que haja um período de evolução de seus recursos e formas de utilização, em direção ao aperfeiçoamento.

Deseja-se analisar, porém, se o desenvolvimento realizado até então é suficiente para que a qualidade de suas previsões possa superar ou, pelo menos, igualar a qualidade dos resultados obtidos com as técnicas em uso corrente.

Modelos empíricos lineares são, então, ajustados para as mesmas informações utilizadas na melhor alternativa resultante da modelagem com sistema especialista. As comparações são feitas, principalmente, como referência para avaliação do uso destes sistemas.

O SELF (Sistema Especialista com uso de Lógica “Fuzzy”) é um aplicativo desenvolvido para a realização desta pesquisa, onde são consolidados os aspectos da metodologia no que diz respeito à aplicação da lógica difusa.

Diversos procedimentos específicos foram estabelecidos, com base na análise teórica e na preferência pessoal, para as diversas etapas de funcionamento do sistema. Estas escolhas dizem respeito à atribuição do grau de pertinência ao conseqüente a partir do grau de

acionamento, à composição das funções de pertinência resultantes da aplicação de todas as regras associativas, e à desquantização, bem como à escolha da categoria, a partir da configuração resultante dos conjuntos difusos, na variável explicada.

A experimentação de outras hipóteses além das adotadas é desejável, porém considerou-se mais importante, por hora, a análise preliminar da viabilidade da técnica para esta linha de pesquisas, pela confrontação com modelos tradicionais em uma situação onde aspectos comuns ao problema da previsão em tempo atual constituem-se em desafios a serem solucionados.

O módulo de Operação, e, mais especificamente, o sub-módulo de Aprendizado, incorporam diversos aperfeiçoamentos dos métodos encontrados na literatura mais recente, tanto dos procedimentos Organizativos quanto dos Adaptativos.

A interpretação das previsões sob forma de categorias difusas é condicionada à probabilidade de acerto, sendo idealizados coeficientes representativos das frequências de ocorrência, totais e parciais, nas categorias previstas, como base para o estabelecimento de critérios de avaliação do desempenho e validade das previsões sob esta forma.

Este trabalho constitui-se, portanto, no teste de campo para estes recursos, os quais são abordados, quanto aos aspectos teóricos e construtivos, junto à descrição do programa, a qual é feita com ênfase na especificação geral e nos recursos de operação.

Uma possibilidade interessante aproveitada é a utilização, como antecedentes para o SELF, das previsões executadas com um modelo convencional, com o objetivo de melhorá-las, ou, pelo menos, convertê-las em previsões difusamente categorizadas.

O mesmo recurso é utilizado com a finalidade de análise do desempenho do modelo, uma vez que pode-se pesquisar a categorização necessária para que um certo nível de eficiência seja alcançado. Assim, quanto menos preciso o modelo, maior a amplitude necessária às categorias para que resulte em uma frequência previamente estipulada de acertos. Conseqüentemente, menor o número de categorias, no domínio da variável explicada.

3. 2. A Estrutura e os Recursos do SELF

3. 2. 1. Generalidades

O SELF (Sistema Especialista com uso da Lógica "Fuzzy") é um programa orientado por leques de opções, constituindo-se em uma ferramenta para a investigação e utilização de relações entre variáveis e que faz uso, para consultas individuais ou simulação, de

conhecimento especialista gerado (aprendido a partir de amostras numéricas, simbólicas ou mistas), ou existente, transmitido por perito.

O objetivo principal do desenvolvimento do programa é o domínio da técnica. Através da experimentação, busca-se a verificação e a consolidação, bem como a ampliação, do conhecimento existente sobre sistemas especialistas baseados em lógica difusa. Além disso, deseja-se uma plataforma para a pesquisa e desenvolvimentos futuros.

A estrutura do SELF é baseada na separação rigorosa das bibliotecas de conhecimento, dos dados e do programa, com seus recursos (figura 3.1) de edição, visualização, operação, leitura e gravação.



Figura 3.1 - SELF : Tela Principal.

O princípio básico do sistema é a categorização difusa, ou “fuzzy” (Zadeh, 1965), do espaço amostral das variáveis, e a pesquisa ou utilização das relações existentes, por meio de conhecimento constituído de regras associativas.

Portanto, a capacidade de gerar conhecimento a partir de amostras, bem como de utilizar as regras resultantes, para simulações com séries de registros, ou para consultas individuais, em situações práticas, são os principais objetivos pretendidos com a realização do SELF. Os recursos concebidos para a execução destas tarefas compõe o módulo de Operação, estruturado em três funções distintas, as quais são :

- A Consulta, a qual consiste na extração de um valor ou símbolo conseqüente individual a partir dos valores (numéricos ou qualitativos) disponíveis para as variáveis explicativas;
- A Simulação constitui-se de consultas seqüenciais automáticas, com a finalidade de gerar séries da variável explicada a partir de séries das variáveis explicativas. A Simulação pode ser com ou sem a Verificação, quando os resultados são comparados com as observações para extração de estatísticas de avaliação;
- O Aprendizado, o qual pode ser Organizativo (pesquisa das regras associativas, entre conjuntos com dimensões e funções de pertinência estabelecidos para cada variável), ou Adaptativo (os próprios conjuntos são questionados, quanto à amplitude, posição e forma da função de pertinência, bem como os pesos atribuídos às regras associativas);

3. 2. 2. Os Conjuntos Difusos

Os conjuntos difusos são agrupados, no SELF, em tipos previamente definidos, os quais são conjuntos normais, caracterizados por suas formas e proporções fixas, e por um ponto de referência, o protótipo, o qual possui grau máximo de pertinência.

O SELF aceita três tipos para as funções de pertinência dos conjuntos difusos, ou seja, triangular, trapezoidal e sigmóide, e uma quarta forma, retangular, que não é, na verdade, difusa, uma vez que não apresenta graduações de pertinência na transição (limite) entre conjuntos adjacentes.

As alternativas, quanto ao número de conjuntos para cada variável, dependem de escolha do usuário, podendo ser de dois (2), três (3), cinco (5), sete (7) ou nove (9) conjuntos.

Embora possa ser desejável, em muitos casos, o emprego de uma quantização mais refinada, optou-se, nesta primeira versão do SELF, pelo máximo de nove (9) conjuntos, para não comprometer demais o número de variáveis com que deseja-se trabalhar, tendo-se em conta limitações de memória computacional.

A conceitualização é limitada a nomes preconcebidos, os quais são associados aos conjuntos, sendo : **EB** (Extremamente Baixo), **MB** (Muito Baixo), **BA** (Baixo), **BM** (Baixo Médio), **ME** (Médio), **AM** (Alto Médio), **AL** (Alto), **MA** (Muito Alto) e **EA** (Extremamente Alto). Portanto, ao optar-se por uma das cinco opções para a quantização do domínio de uma

variável, o programa atribui nomes correspondentes aos conjuntos, em função do seu número, os quais são descritos na tabela 3.1.

Tabela 3.1 - Símbolos atribuídos aos conjuntos.

Nº de Conjuntos	Nomes Atribuídos
2	BA e AL
3	BA, ME e AL
5	MB, BA, ME, AL e MA
7	MB, BA, BM, ME, AM, AL e MA
9	EB, MB, BA, BM, ME, AM, AL, MA, EA

A quantização e a conceitualização do domínio podem ser definidas diferentemente para cada variável, havendo condições, por meio de edição direta, para a decisão do especialista. Existe também o recurso de buscar-se, por meio de técnicas automáticas de aprendizado a partir de amostras, a partição mais conveniente.

Na figura 3.2, tem-se exemplos de cada um dos tipos de conjuntos, descritos a seguir. As condições usualmente recomendadas para a formação dos conjuntos são atendidas. Por exemplo, a soma dos máximos graus de pertinência, no domínio, é sempre 1.

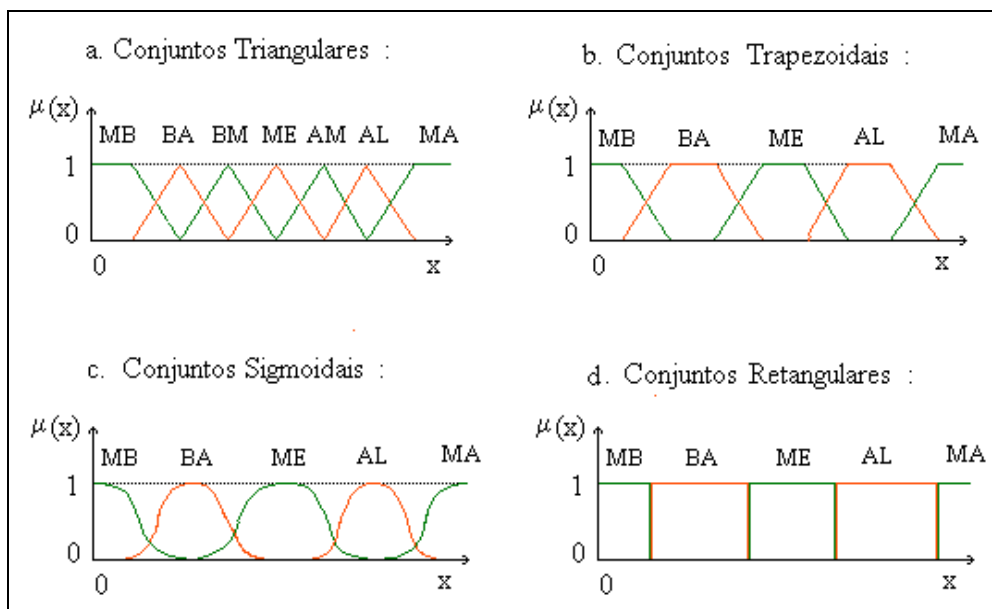


Figura 3.2 - Tipos de conjuntos difusos do SELF.

No tipo triangular, o valor de referência (protótipo) de cada conjunto coincide com os limites dos conjuntos adjacentes. Neste ponto, os graus de pertinência destes são zero. Nos

extremos, para os valores externos ao valor de referência do conjunto, os graus de pertinência são constantes e iguais à unidade.

Os limites, nos conjuntos trapezoidais, são sempre de 50% da distância entre os protótipos ou pontos de referência de dois conjuntos adjacentes, ficando o restante igualmente distribuído para os núcleos de cada conjunto.

A função sigmóide, por sua vez, estabelece transição suave entre os conjuntos, de forma que o grau de pertinência será exatamente 1 apenas para os protótipos dos conjuntos, ou externamente a estes pontos, no caso de conjuntos extremos.

Finalmente, os conjuntos retangulares (na verdade, não-difusos), apresentam grau de pertinência 1 em todo o seu domínio, sem transição para os conjuntos adjacentes. A relação das distâncias dos pontos de referência aos limites entre os conjuntos retangulares é semelhante à dos conjuntos trapezoidais.

3. 2. 3. As Bibliotecas de Conhecimento

A estrutura do SELF confere flexibilidade para que este possa ser utilizado para solucionar diversos problemas, cada um com o conhecimento especialista correspondente, sob forma de conjuntos de regras associativas.

As regras associativas são armazenadas em bibliotecas de conhecimentos, as quais podem sofrer alterações ou ajustes, em função das modificações detectadas, ou da aquisição de novas informações que acrescentem conhecimento para a compreensão do funcionamento dos fenômenos ou processos representados.

Uma biblioteca de conhecimentos, armazenada em formato texto, é constituída da identificação e descrição da quantização adotada para cada variável envolvida, com o número e tipo dos conjuntos, bem como os valores característicos e nome de cada conjunto difuso, além das regras associativas.

A formação ou a alteração da biblioteca de conhecimentos pode ser realizada através do próprio SELF, ou com qualquer recurso de edição (Word, etc.). O espaço de memória comprometido é pequeno, mesmo com um grande número de regras associativas (admite-se, na versão atual, até 3000 regras, podendo-se ampliar, se necessário).

Cada regra determina uma relação de associação (operação interseção - \cap), entre conjuntos, conforme exemplo :

$$\text{Se } \mu_{ME}(x_1) > 0 \text{ E } \mu_{MB}(x_2) > 0 \text{ E } \mu_{AL}(x_3) > 0 \text{ Então } \mu_{ME}(y) = \text{MIN}(\mu_{ME}(x_1), \mu_{MB}(x_2), \mu_{AL}(x_3)). \omega_r$$

A notação da regra é feita entre parênteses, com as condições separadas entre si por vírgulas, e da consequência por ponto-e-vírgula. O peso (ω_r) atribuído à regra é escrito fora do parêntese, separado pelo símbolo “:”, e tem a função de ponderar regras conflitantes.

No exemplo acima, pode-se especificar (ME, MB, AL, NR, NR; ME) : ω_r , onde ME, MB e AL significam, respectivamente, graus MÉDIO, MUITO BAIXO e ALTO, para as três variáveis explicativas. NR quer dizer “não relacionado”, significando que estas variáveis não participam, ou que existem apenas três antecedentes.

Pela simplicidade, optou-se por limitar, por enquanto, as operações entre conjuntos de variáveis explicativas ao tipo conjuntivo (\cap), uma vez que o operador \cup pode ser substituído pelo emprego de regras independentes para cada antecedente. A presença de um operador disjuntivo na natureza de um fenômeno em estudo pode ser detectada pela análise das regras aprendidas, na biblioteca dos conhecimentos gerados. Caso isto ocorra, pode-se reduzir o número de regras do sistema.

Um risco possível na operação de sistemas especialistas difusos, que tende a aumentar com o incremento da complexidade, é o de acontecer “falta de conhecimento”, o que significa que o sistema não possui nenhuma regra cobrindo determinada combinação de ocorrências, para proporcionar uma resposta.

A alternativa mais imediata é a redução da quantização das variáveis, ou a redução do número de variáveis explicativas, o que implica em sacrifício da precisão. Uma vantagem adicional de se renunciar a parte dos antecedentes é a diminuição do risco de eventual não acesso às informações, em casos de degradação do sistema, comuns em situações de emergência.

No SELF, é idealizado o recurso das bibliotecas combinadas de conhecimento, com conjuntos de regras totais (todas as variáveis contribuem com informações), e conjuntos de regras parciais, onde parte das componentes não contribui para a regra, para prevenir ausência de informações ou “falta de conhecimento”, que podem afetar, ora uma, ora outra variável.

Por exemplo, as regras (MB, BA, AL; BA) e (MB, BA, BA; AL) podem não ser aplicáveis, na ausência de informações sobre a terceira componente explicativa. Ou, se o dado relativo a esta componente for um valor não previsto no conjunto de regras totais (por exemplo, ME). Neste caso, o modelo não seria aplicável, resultando em “falta de conhecimento”. Porém, a existência, na biblioteca de conhecimentos, da regra (MB, BA, NR; ME), por exemplo, onde NR significa “não relacionado”, corresponde à utilização de um modelo alternativo, mais simplificado, podendo prevenir estas ocorrências, embora reduzindo

a precisão das respostas que resultariam do modelo completo, se houvesse conhecimento suficiente para operá-lo.

Os conjuntos de regras são acionados de forma hierarquizada, havendo dois critérios. O primeiro, é de que, sempre que pelo menos uma das regras totais (modelo completo) é acionada por um registro, as regras parciais não o serão, uma vez que os modelos alternativos, simplificados, não são necessários. O outro critério, quando existem mais de um modelo alternativo, representados na biblioteca de conhecimentos, resulta da adoção de pesos diferenciados para as regras correspondentes a cada modelo.

Estes critérios permitem a opção automática pelo modelo mais completo, ou, se este não for satisfatório, seja por ausência de conhecimento ou de informações para ser acionado, pelo modelo hierarquicamente considerado mais eficiente, o qual é previamente contemplado com pesos maiores.

Pode-se, portanto, ter sempre na biblioteca de conhecimentos uma regra suficientemente simples para dar uma solução, mesmo que menos precisa, evitando-se casos de "falta de conhecimento".

Este recurso é equivalente à utilização de sistemas com diversos modelos, para prevenção da ocorrência de degradação progressiva de acesso a informações, o que costuma acontecer justamente em situações de emergência.

3. 2. 4. As Opções Metodológicas

Os dados de entrada podem ser, tanto valores numéricos quantitativos quanto valores qualitativos ou simbólicos. Assim, uma variável pode ser numérica ou qualitativa, ou, no caso de uma série de dados, possuir elementos ora simbólicos ora numéricos.

Caso o dado seja qualitativo (correspondendo a um dos conjuntos difusos que compõe a variável), são atribuídos graus 1 e 0,5 para este conjunto e seus adjacentes, respectivamente, como consequência da justaposição adotada nos conjuntos utilizados pelo SELF, uma vez que resulta neste grau de pertinência para os pontos de interseção (Kasabov, 1996). A exceção ocorre com o uso de conjuntos retangulares (não-difusos), para os quais o grau atribuído aos conjuntos adjacentes é zero.

A atribuição, como consequência da aplicação de cada regra, do grau de pertinência ao conjunto difuso consequente, a partir do grau de acionamento, é feita pelo método do mínimo, uma vez que o método do produto, mesmo sendo mais complexo para implementar, não implica em melhoria apreciável, já que as diferenças situam-se em nível de detalhe.

O uso da técnica de composição aditiva, recomendada por Kosko (1992), implica adição ou reforço dos efeitos dos antecedentes de mais de uma regra sobre o conseqüente comum, quando for o caso. Pode-se, porém, não estar representando perfeitamente o comportamento de um sistema, quando os efeitos não forem aditivos. Além disso, os resultados passam a ser muito dependentes da freqüência.

Comprovou-se, no entanto, em testes preliminares, que seu uso realmente reduz ou mesmo elimina a ocorrência de ambigüidades e achatamentos das funções de pertinência resultantes nos conjuntos conseqüentes, além de proporcionar resultados numéricos suficientemente aproximados, o que motivou sua adoção, como técnica de composição para operações com o SELF, para efeito desta pesquisa.

Os pesos (ω_r) para a ponderação diferenciada das regras associativas (os quais são multiplicados aos graus de acionamento resultantes de cada regra) podem ser adotados pelo julgamento pessoal do perito em função da importância atribuída, utilizando-se para isso os recursos da Edição do SELF. Pode-se utilizar ainda como pesos, conforme amplamente aceito (Kasabov, 1996), a freqüência ponderada de ocorrência de cada regra, durante o aprendizado.

Outra possibilidade, também oferecida pelo SELF, é o ajuste dos pesos como parâmetros (Kosko, 1992) por um procedimento de otimização por tentativas, buscando-se os valores que proporcionam melhores respostas em função das estatísticas calculadas. Tanto o cálculo da freqüência de ocorrência das regras como o ajuste por tentativas dos pesos são opções disponíveis no módulo de Aprendizado, dos recursos da Operação.

Os métodos de singularização ou desquantização existentes foram comparados, em função dos critérios da continuidade, plausibilidade, desambigüidade e complexidade computacional (Driankov, 1996), optando-se pelo método das alturas, o qual mostrou-se satisfatório, e compatível com a regra de composição utilizada.

É importante, principalmente tratando-se de uma etapa de apresentação e consolidação da técnica, que os resultados sejam passíveis de comparação com as respostas obtidas com uso de modelos tradicionais, as quais são, via de regra, apresentadas como valores numéricos.

Tendo-se em conta que não tem sentido, em situações práticas, a execução de previsões numéricas e categorizadas não coincidentes, e que as previsões numéricas são, por enquanto, ainda muito importantes, optou-se pelo critério de adoção para a categoria prevista, do conjunto difuso ao qual pertence, com maior grau de pertinência, o valor numérico resultante da desquantização.

Este critério é consistente, uma vez que, se o valor observado realiza-se nas proximidades do valor previsto, é razoável supor-se que ambos ocorram na mesma categoria.

Na figura 3.3, apresenta-se um esquema do funcionamento do sistema, comparativamente ao uso de modelos convencionais, com respeito às entradas e saídas possíveis.

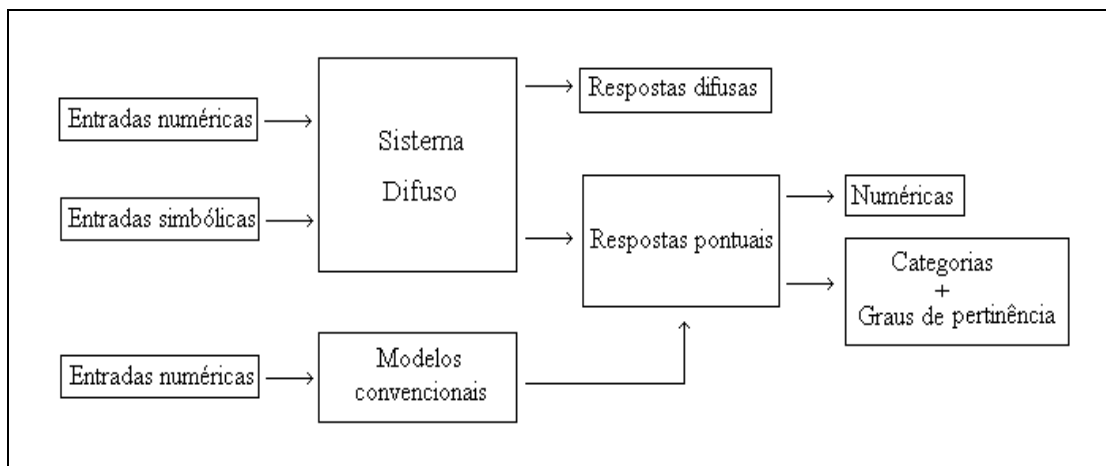


Figura 3.3 – Sistemas difusos e modelos convencionais.

As respostas difusas referem-se à configuração resultante dos conjuntos difusos conseqüentes, a qual é disponível, inclusive, em forma gráfica, na operação de consulta. As respostas pontuais, por sua vez, são apresentadas na forma de um valor numérico, e também na forma das categorias acionadas por este valor, na variável explicada, e os respectivos graus de pertinência.

Os modelos convencionais, os quais apresentam, via de regra, resultados numéricos, podem ter estes resultados convertidos à forma de categorias com graus de pertinência associados, por meio do mesmo mecanismo, o que possibilita comparações de resultados sob forma de categorias.

3. 2. 5. A Consulta e a Simulação

A Consulta é o recurso do SELF para a aplicação prática (em tempo atual, no caso de previsão), dos conhecimentos existentes. Solicita-se resposta a determinada situação, representada pelas informações conhecidas sobre o estado das variáveis explicativas, sob forma da combinação correspondente dos antecedentes.

As consultas, bem como as respostas resultantes, são sempre individuais, ou seja, são executadas a partir de realizações singulares de cada combinação de antecedentes (valores ou símbolos representativos do estado das variáveis explicativas), que devem ser informados. A resposta à consulta é o conseqüente (valor ou símbolo representativo do estado estimado para a variável explicada), o qual é fornecido sempre nas duas formas, numérica e simbólica.

A solução fornecida resulta da aplicação, em paralelo, de todas as regras presentes na biblioteca de conhecimentos utilizada. Esta biblioteca pode ser simples, ou resultante da combinação de dois ou mais grupos de regras (cada grupo representando um modelo) com configuração diferente de antecedentes.

O conjunto de procedimentos utilizados, com visualização do encadeamento funcional e das diversas opções metodológicas adotadas (método das alturas, composição aditiva, etc.), é esquematizado na figura 3.4.

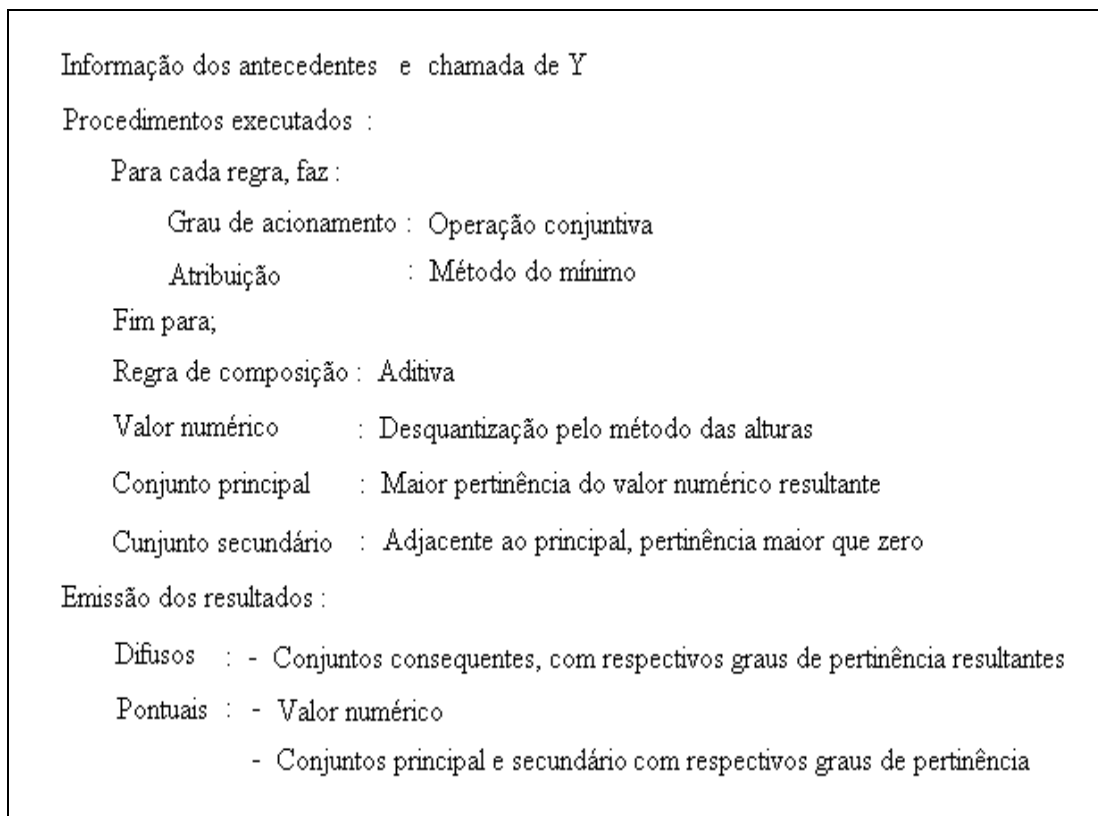


Figura 3.4 – A Consulta : Descrição dos procedimentos.

O grau de acionamento correspondente aos antecedentes fornecidos é determinado, para cada regra, pela operação conjuntiva. Se o grau de acionamento é maior do que zero, implica que a regra é relevante para o caso, resultando em atribuição diferente de zero, pelo método do mínimo. A composição aditiva é então utilizada, para combinação dos consequentes gerados por cada regra associativa.

A desquantização, pelo método das alturas, é utilizada para o cálculo da resposta numérica. O conjunto difuso ao qual esta resposta apresenta maior pertinência é o conjunto principal (CP), e o conjunto adjacente com o segundo maior grau de pertinência, sendo este grau maior do que zero, é o conjunto secundário (CS).

As respostas, sob forma destes conjuntos (CP e CS), juntamente com os graus de pertinência associados, podem ser facilmente convertidas em respostas numéricas, constituindo-se, portanto, em outra forma para apresentação dos resultados pontuais. Porém, independentemente dos graus de pertinência associados, estes conjuntos constituem-se também em uma alternativa para a adoção de respostas sob forma de categorias.

Na figura 3.5 tem-se um exemplo hipotético com quatro variáveis explicativas onde, para as duas primeiras, são fornecidos, como antecedentes, valores numéricos, enquanto que, para as demais, é informado tratarem-se de grandezas rotuladas como MÉDIA (ME) e BAIXA (BA), respectivamente.

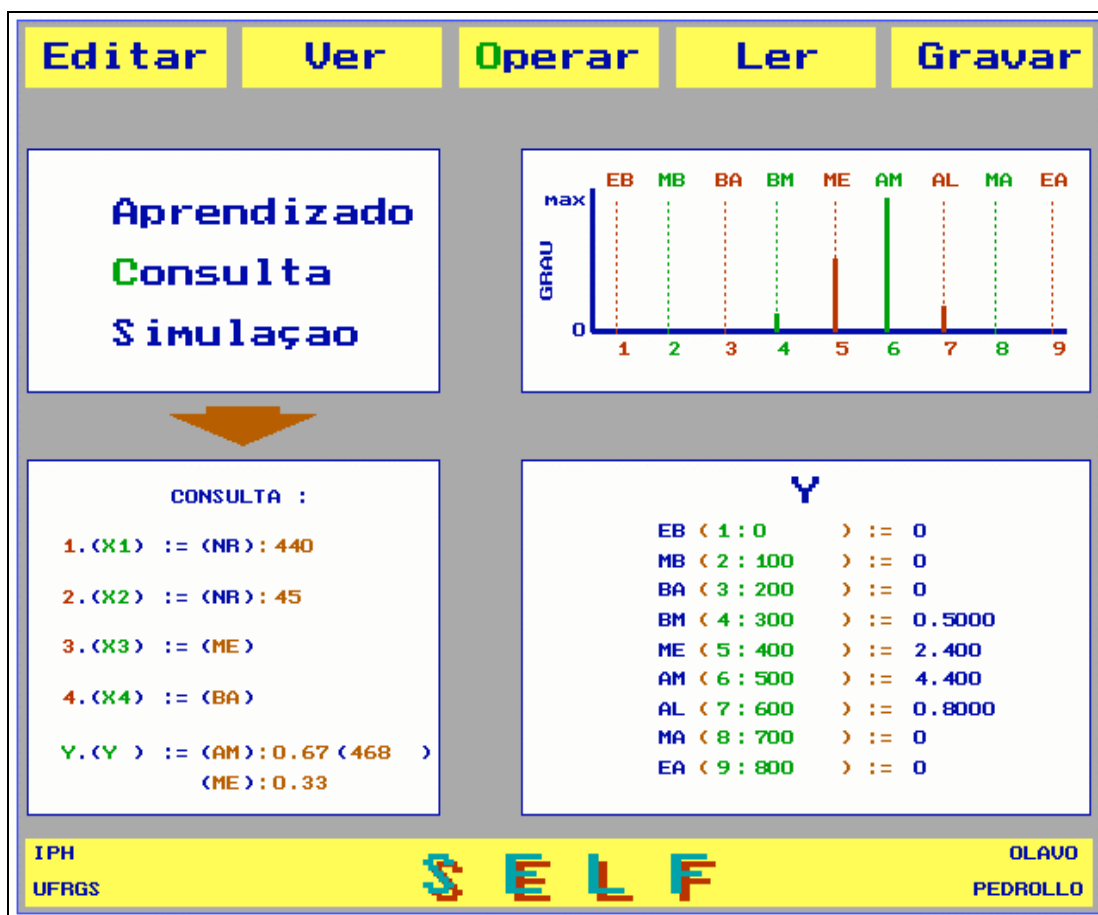


Figura 3.5 – A Consulta : Exemplo de uso.

A chamada de Y (variável explicada) tem como consequência a apresentação do resultado da inferência na forma pontual e difusa. Na forma pontual, tem-se Y ALTO MÉDIO (AM), com grau de pertinência 0,67, correspondendo ao valor numérico 468. Como a pertinência à categoria AM (principal) não é total, o SELF apresenta, abaixo, a categoria secundária MÉDIO (ME) e o grau de pertinência correspondente, o qual é complementar ao anterior.

Na forma difusa, são apresentados, inclusive graficamente, para facilitar a visualização, os graus de pertinência agregados pela regra de composição, de cada conjunto difuso conseqüente. Estes graus de pertinência não são normalizados, pois esta operação não afetaria o resultado da desquantização.

Uma interpretação difusa, resultante da adoção de uma categoria, representada simplesmente pelo conjunto principal, por exemplo, pode ser mais confiável, principalmente devido à imprecisão freqüentemente presente nos dados e nos processos.

Uma vez que as respostas, sob forma de categorias, também são sujeitas a erros de estimação, a redefinição da interpretação das previsões, expressas desta forma, deve partir de estudos prévios, realizados através de simulações com séries amostrais.

Simulações podem indicar, por exemplo, a freqüência de acertos quando adota-se como previsão o conjunto principal. Neste caso, o critério para aceitar-se que houve acerto pode ser total (quando o valor observado pertence a esta categoria com grau maior do que a qualquer outra), ou parcial (quando o valor observado apresenta grau de pertinência maior do que zero à categoria prevista). Pode-se também adotar os dois critérios, com freqüências diferentes estabelecidas para cada um. Desta forma, passa a ser possível adotar-se, com riscos conhecidos, os conjuntos principais estimados, como previsões sob a forma de categorias.

Pode-se verificar, também, com que freqüência ocorrem valores observados na categoria secundária. Na medida em que as observações que ocorrem fora do conjunto principal acontecerem no conjunto secundário, então estas categorias podem, de alguma forma, serem incorporadas às previsões.

Nestes casos, o auxílio prestado à tomada de decisões pode ser importante, pois tem-se, além da previsão, a indicação da categoria alternativa, caso haja erro. Além disso, tem-se a estimativa da direção do erro possível (para mais ou para menos), além de sua probabilidade, estimada pelas freqüências calculadas.

Portanto, as previsões categorizadas podem ser divulgadas como previsões “entre CP e CS, mais para CP”, ou algo assim. Em nível técnico, conhecem-se as probabilidades associadas, sabendo-se que a observação pode até vir a ocorrer mais próxima de CS, porém não deve acontecer em direção oposta, em relação a CP.

É possível, quando há insuficiência de conhecimento e a consulta é feita em uma região do espaço conceitual não coberta pelas regras associativas, que não seja fornecida a resposta solicitada. Neste caso, a interferência do perito, ou amostragens mais completas do fenômeno para complementação da biblioteca de conhecimentos, são indispensáveis para a busca da solução.

A participação do especialista é sempre importante nas fases de operação, uma vez que podem ocorrer situações imprevistas, com interferência de novas variáveis.

Na Operação de Simulação, as séries de valores da variável explicada são geradas a partir das séries de valores das variáveis explicativas (podendo estes serem numéricos ou não), fazendo-se uso de uma biblioteca de conhecimentos existente.

A série correspondente com as respostas é emitida, podendo-se também, se desejado, gravar arquivos com os registros formados pelos valores das variáveis explicativas e os valores da variável explicada. Estes valores podem ser, tanto para os antecedentes como para os conseqüentes, numéricos ou simbólicos. Caso sejam fornecidos, além dos dados das variáveis antecedentes, valores amostrais da variável conseqüente, o SELF pode realizar uma Operação de Simulação com Verificação.

A Simulação com Verificação (figura 3.6) consiste na geração de valores conseqüentes e no cálculo de estatísticas para a quantificação da qualidade dos resultados partir da comparação com a série de valores observados da variável explicada. O cálculo de coeficientes de desempenho, de forma acumulada, ao longo de diversas bateladas, é possível uma vez que estes coeficientes dependem sempre de somatórios.



Figura 3.6 – Simulação com Verificação.

As estatísticas podem ser calculadas acumulativamente, no caso de serem utilizadas, sequencialmente, diversas séries amostrais, ou individualmente, para cada série, sendo

apresentadas na figura 3.7, juntamente com um exemplo dos resultados da Simulação, confrontados visualmente com as respectivas observações da variável predita.



Figura 3.7 – Emissão dos resultados e estatísticas de desempenho.

Além dos coeficientes descritos anteriormente, no item 2.4, tem-se, ainda como estatísticas pontuais, o erro máximo (Ex), e o número de falhas de conhecimento (nF). O erro máximo é o maior valor absoluto das diferenças individuais entre previsões e as observações correspondentes.

O número de falhas de conhecimento ocorrida durante a simulação corresponde ao número de vezes em que determinado conjunto de antecedentes não é relacionado por nenhuma regra da biblioteca de conhecimentos, não gerando, portanto, nenhum consequente.

No caso de previsões por categorias difusas, porém, necessita-se de uma nova classe de estatísticas de desempenho, as quais possam ser utilizadas como estimativas para a quantificação da capacidade do modelo, quando utilizado para esta modalidade de previsões.

São idealizados neste trabalho, portanto, os coeficientes de agrupamento, os quais são calculados como frequências, expressas em forma de porcentagens, das ocorrências das observações nas respectivas faixas de domínio, em relação aos conjuntos principais (CP) e secundários (CS), ilustradas na figura 3.8.

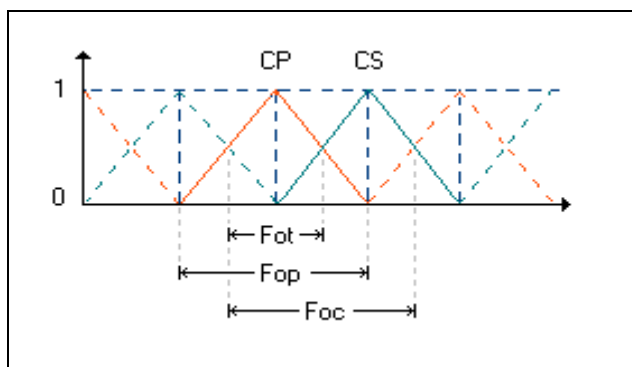


Figura 3.8 – Domínio dos coeficientes de agrupamento.

A frequência de ocorrências totais (Fot) e a frequência de ocorrências parciais (Fop) representam o quanto o modelo acertaria se fosse utilizado para previsão da ocorrência do valor observado no conjunto principal (CP), ou seja, o conjunto resposta que apresenta maior grau de pertinência.

No primeiro caso, o critério para considerar-se correta a previsão é de que a observação apresente pertinência, ao conjunto previsto, maior do que a qualquer outro conjunto da variável predita.

No segundo caso, o critério é menos rigoroso, sendo exigido apenas que o grau de pertinência seja maior do que zero.

A frequência de ocorrências totais combinadas (Foc), por sua vez, representa a frequência com que as observações ocorrem, com maior pertinência, ou ao conjunto principal, (CP) ou ao conjunto secundário (CS).

Além da avaliação da eficiência dos modelos representados, para a previsão, estes coeficientes são úteis para o estabelecimento de critérios para pesquisa da configuração dos conjuntos difusos da variável explicada, que pode ser realizada por simulações.

Por exemplo, suponhamos que seja desejável que as observações, em pelo menos 90% dos casos, ocorram na categoria principal, e que, nos casos restantes, pelo menos 90% ocorram na categoria secundária. Ora, isto significa que precisamos de uma categorização que resulte, para um grande número de consultas, em pelo menos 90% para Fot, e pelo menos 99% para Foc.

Pode-se, adicionalmente, estabelecer que com, por exemplo, pelo menos 95% de frequência, as observações pertençam, com algum grau, ao conjunto principal previsto. Neste caso, teria que resultar, após as consultas realizadas, em pelo menos 95% para Fop.

3. 2. 6. O Aprendizado

3. 2. 6. 1. Generalidades

O objetivo dos métodos de aprendizado é a formação de conhecimento a partir das amostras de registros observados. O conhecimento é expresso sob a forma das regras associativas, que representam as conexões lógicas existentes entre os conjuntos difusos nos quais são quantizadas as variáveis.

Os registros são compostos de elementos, de natureza numérica ou simbólica (na forma de conceitos de intensidade : MB, BA, AL, etc.), os quais correspondem aos antecedentes (conjuntos difusos das variáveis explicativas) e aos conseqüentes (conjuntos difusos da variável explicada). Em uma mesma amostra de registros numéricos pode ocorrer, por exemplo, que devido às imprecisões das observações, alguns de seus elementos sejam representados por conceitos.

Portanto, nos procedimentos de aprendizado pesquisam-se amostras, constituídas de registros numéricos, simbólicos ou mistos (alguns elementos podem ser numéricos e outros conceituais), buscando-se identificar as combinações significativas existentes entre os grupos ou categorias do conjunto de variáveis submetidas. Investigam-se, na variável explicada, as distribuições dos conjuntos difusos resultantes e as funções de pertinência associadas que melhor evidenciam estas combinações.

A etapa final de um processo de aprendizado é a formação da biblioteca de regras associativas, ou biblioteca de conhecimentos, a partir das conexões observadas. É possível a atribuição de um “fator de confiança”, o qual pode variar de 0 a 1, para cada registro, em função do grau de confiabilidade atribuído a este. Este “fator de confiança” (Fc) é utilizado como ponderador da importância atribuída a este registro, na formação da biblioteca de regras associativas.

Adota-se a classificação de Driankov (1996) para os métodos de aprendizado, segundo a qual estes constituem-se em Organizativos ou Adaptativos. Os métodos Organizativos atuam sobre os conjuntos difusos estabelecidos, determinando regras associativas entre estes, enquanto que os Adaptativos modificam os conjuntos, ou os pesos atribuídos às regras associativas, podendo ser realizados em conjunto com os anteriores.

Existem, ainda, certas condições de aplicação, ou opções, tanto para os métodos Organizativos quanto para os métodos Adaptativos. Estas opções são chamadas, no SELF, de Objetivos de cada aplicação realizada.

Nos métodos Organizativos, deve-se decidir se deseja-se refazer o aprendizado com a amostra atual, esquecendo-se as regras aprendidas até então, ou acumular novas regras ao conhecimento já adquirido.

Da mesma forma, para os procedimentos Adaptativos, tem-se por Objetivos as opções de refazer as regras associativas, ou manter-se as regras atuais e realizar apenas as adaptações dos conjuntos ou dos pesos associados a estes.

3. 2. 6. 2. Aprendizado Organizativo

A idéia básica para a implementação do método Organizativo proposto é a análise de agrupamentos deduzidos da amostra, com adoção, para cada combinação de antecedentes, do conjunto correspondente na variável explicada cuja ocorrência é mais freqüente.

Para tanto, é proposta uma forma ampliada para representar matricialmente o conhecimento, em relação às FAM's (Kosko, 1992). Incorpora-se uma dimensão adicional, para representar os conjuntos da variável explicada, liberando desta finalidade os elementos desta matriz.

Estes elementos passam a ser, no decorrer do processo, representativos da freqüência relativa com que cada conjunto da variável explicada é acionado, para cada combinação possível de antecedentes, uma vez que resultam de somatórios de ocorrências, ponderadas pelos graus de pertinência aos conjuntos difusos envolvidos. Os pesos (ω_r) atribuídos a cada regra são calculados, no final do processo de aprendizado, a partir destes elementos.

Na figura 3.9, tem-se a ilustração do elemento matricial que representa uma regra associativa com peso ω_r , em um sistema com duas variáveis explicativas (x, y) e uma explicada (z), a qual associa os respectivos conjuntos difusos x_h e y_i ao conjunto difuso z_j .




Figura 3.9 - Representação do elemento matricial ($x_h, y_i; z_j$) : ω_r

Esta forma de representação do conhecimento é mais completa do que a FAM, pois incorpora a informação da importância, atribuída ou calculada, da conexão. Na ocorrência de novas informações, os elementos podem ser alterados pela reconsideração destas frequências, havendo modificação ou incorporação de conhecimentos.

Tendo-se em conta as funções desta matriz, esta pode chamar-se matriz de (agregação) de conhecimentos, ou matriz cognitiva. Ou, considerando-se a natureza de seus elementos, matriz conectiva. O conhecimento armazenado em uma forma matricial pode ser transferido para regras associativas, e vice-versa. Nos procedimentos propostos, as transferências nos dois sentidos são importantes.

A matriz de agregação de conhecimentos, na verdade, é teórica, uma vez que, devido às limitações de memória, utilizam-se diversas matrizes menores, constituindo uma estrutura de memória particionada. Os procedimentos computacionais desenvolvidos acessam estas matrizes, funcionando, na prática, como se fossem apenas uma.

Mesmo com o artifício do particionamento em estruturas menores, para representarem a matriz cognitiva sob forma de memórias associativas, o sistema ainda é limitado pela questão da dimensionalidade, a qual impõe, no caso do SELF, um máximo de cinco variáveis antecedentes e uma variável conseqüente, quantizadas em nove categorias cada uma, resultando 531441 elementos, sob forma de valores numéricos.

Uma vez que cada valor numérico de cada variável pode pertencer a mais de um conjunto difuso no universo quantizado desta variável, com graus de pertinência correspondentes, o valor a ser agregado à matriz cognitiva é previamente ponderado pelos respectivos graus de pertinência, e também pelo fator de confiança adotado para o registro, adotando-se, portanto, a sugestão de Wang e Mendel (1992).

Nas aplicações destes autores, porém, amostras podem ser geradas à vontade, o que possibilitou aquisição suficiente de conhecimento a partir do aproveitamento apenas do conjunto mais favorecido de cada registro. Em situações práticas, as dificuldades existentes para obtenção de séries extensas de observações exigem soluções mais criativas.

Portanto, procura-se extrair maior quantidade de informações das amostras, com maior eficiência. Aplicações preliminares comprovam um aumento em torno de 20% no número de regras geradas pelo método desenvolvido para o SELF, em comparação com o método anterior, com limitação aos conjuntos mais favorecidos para a geração de regras. Alguns casos de “falta de conhecimento” talvez sejam, eventualmente, resolvidos após este aperfeiçoamento.

Além da questão da eficiência na extração amostral de conhecimentos, existem dois aspectos adicionais a serem considerados, ambos relativos a ocorrências nos limites entre conjuntos adjacentes :

- O primeiro é a possibilidade de que fatores aleatórios ou pequenos erros de leitura condicionem o conjunto errado;
- O segundo é que os conjuntos adotados podem não corresponder aos agrupamentos que realmente ocorrem. Neste caso, necessita-se de duas regras, com respectivos pesos, para representar uma única relação, conforme exemplificado na figura 3.10.

Neste último caso, uma única regra seria tendenciosa, e a geração de duas regras associativas, a partir do mesmo registro, seria possível apenas pela aceitação do segundo conjunto mais favorecido de cada variável (ou conjunto secundário).




Figura 3.10 - Agrupamento no limite entre conjuntos.

Portanto, o método que o SELF utiliza 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, o que ocorre quando os valores pontuais das variáveis situam-se nos limites entre conjuntos difusos adjacentes.

O processo utilizado para a agregação de conhecimentos à matriz cognitiva, para cada registro da amostra, é ilustrado na figura 3.11. As duas idéias utilizadas para extração de regras difusas não são mutuamente excludentes, além do que, quando não são adequadas, têm seu peso reduzido pelos produtos realizados. Estas idéias são :

- Geração de regras em função dos conjuntos secundários de cada variável;

- Geração de regras pelas combinações possíveis entre conjuntos principais e secundários.

Registro = (x, y, z) : Fc

Cálculo dos graus de pertinência :

Conjuntos mais favorecidos (i) = $\mu_{x_i}(x)$, $\mu_{y_i}(y)$ e $\mu_{z_i}(z)$

Conjuntos secundários (j) = $\mu_{x_j}(x)$, $\mu_{y_j}(y)$ e $\mu_{z_j}(z)$

Para os conjuntos principais, faz :

$f = Fc \mu_{x_i}(x) \mu_{y_i}(y) \mu_{z_i}(z)$

$M(x_i, y_i, z_i) = M(x_i, y_i, z_i) + f$

Fim para;

Para os conjuntos secundários, faz :

$g = Fc \mu_{x_j}(x) \mu_{y_j}(y) \mu_{z_j}(z)$

$M(x_j, y_j, z_j) = M(x_j, y_j, z_j) + g$

Fim para;

Para as combinações i x j, faz :

$h = Fc \mu_{x_{ij}}(x) \mu_{y_{ij}}(y) \mu_{z_{ij}}(z)$

$M(x_{ij}, y_{ij}, z_{ij}) = M(x_{ij}, y_{ij}, z_{ij}) + h$

Fim para;

Figura 3.11 - Matriz Cognitiva : Agregação de conhecimentos.

O procedimento Organizativo assim definido é coerente com os princípios da lógica difusa. Ou seja, se o valor observado de uma variável está associado, ainda que em menor grau, a uma categoria, esta estará, ainda que com grau reduzido, contribuindo para a formação de uma regra associativa, com uma representatividade proporcional a este grau.

Finalmente, 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.

A freqüência de ocorrência deste conjunto é importante por duas razões. Uma, é que é uma medida da confiabilidade da regra pesquisada. E outra, é que pode servir como fator de ponderação sobre a aplicação desta regra (Wang e Mendel, 1992).

A utilização de fatores de ponderação diferenciados sobre cada regra associativa tem sido, com naturezas distintas, recomendada por outros autores. Kosko (1992), por exemplo, sugere que os pesos aplicados sobre as regras sejam usados como parâmetros, ajustados empiricamente, independentemente de seu significado.

Uma vez que deseja-se experimentar, para conhecer a importância desta ponderação, o SELF possui duas alternativas para o aprendizado Organizativo, chamadas de procedimento S-Organizativo e procedimento F-Organizativo.

Na primeira alternativa, os fatores de ponderação são considerados iguais a 1 para todas as regras. Na segunda, adotam-se as frequências resultantes para o conjunto selecionado na pesquisa sobre a matriz cognitiva. O procedimento para a pesquisa das regras associativas na matriz cognitiva (figura 3.12) possui, portanto, 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; Calcula-se, então, o peso correspondente a esta regra (ω_r), segundo o método adotado (S-Organizativo ou F-Organizativo).

Para cada combinação de antecedentes, faz :

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

$$M_z = \text{MAX}_{z_j=1, \dots, nz_j} [M(\text{antecedentes}, z_j)]$$

{ z_j = conjunto difuso conseqüente }

$$Z_M = z_j \text{ correspondente a } M_z$$

$$Fr = 100 M_z / S_z$$

{ Fr = frequência calculada para Z_M }

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

$$\text{Se F-Organizativo, } \omega_r = Fr, \text{ senão } \omega_r = 100$$

$$\text{Regra : (antecedentes; } z_j = Z_M) : \omega_r$$

Fim se;

Fim para;

Figura 3.12 - Pesquisa das regras na matriz cognitiva.

O problema de decidir-se se a frequência das ocorrências ponderadas, a uma categoria da variável conseqüente, é suficiente para caracterizar uma regra passa, necessariamente, pela adoção de um critério arbitrário.

A aceitação de que cada conjunto mais favorecido da variável explicada, para cada combinação possível dos antecedentes, forme uma regra (conforme adotado por Wang e Mendel, 1992), permite a possibilidade de ocorrência de muitas regras pouco significativas, que, embora com ponderação reduzida, podem conduzir a erros de interpretação e oneração do sistema.

Por exemplo, isto pode acontecer se a distribuição das ocorrências ponderadas for aproximadamente uniforme. Neste caso, a adoção de um conjunto conseqüente, por pequena margem mais favorecido, seria um erro, já que esta combinação de antecedentes, para a amostra consultada, provavelmente não determina conseqüente.

Por outro lado, o emprego de critérios muito rigorosos não contribui para maximizar a extração de conhecimentos, sob forma de regras associativas, das amostras.

Se o problema fosse apenas evitar-se distribuições uniformes, um teste de aderência resolveria, mas, claramente, a questão é mais complexa. Além disso, um teste de aderência passa, necessariamente, pela arbitragem de um nível de confiança, e tem validade discutível, se aplicado para pequeno número de intervalos (no caso, as categorias difusas).

A frequência exigida para aceitar-se uma regra associativa afeta, por um lado, o número de regras possíveis de serem extraídas da amostra, e, por outro lado, a significância destas regras. Um compromisso entre extremos deve ser encontrado através de critérios, resultantes de testes realizados em situações práticas.

Assim, com base na experiência adquirida, concluiu-se por adotar os limites de 20%, 25%, 30%, 50% e 75% de frequências mínimas para as ocorrências ponderadas, respectivamente, para as partições da variável conseqüente em 9, 7, 5, 3 e 2 conjuntos da variável explicada, para que seja aceita a regra associativa resultante.

Não é importante que estes limites sejam exatamente ideais, uma vez que regras aceitas em condições duvidosas terão pouco peso associado. O maior risco seria que o excesso de rigor eliminasse regras que poderiam ser importantes.

A natureza de somatórios para a formação da matriz cognitiva permite que esta possa ser atualizada, acumulando-se conhecimento à medida que novas amostras de registros tornem-se disponíveis. No caso de a quantidade de registros ser muito grande (> 1336), excedendo portanto os limites impostos pelas disponibilidades de memória, pode-se trabalhar em bateladas, obtendo-se os mesmos resultados que seriam obtidos com uma amostra única.

A matriz de memórias associativas é reconstruída a partir das regras existentes, e os somatórios são continuados, com a nova amostra. Para tanto, o usuário deve informar ao SELF o Objetivo (Acumulação de Conhecimentos), e os pesos relativos (figura 3.13), em porcentagem, correspondentes, respectivamente, à(s) amostra(s) já processadas e à nova amostra.

A ponderação adotada pode ser proporcional ao número de registros de cada amostragem, ou basear-se também em outros critérios, tendo-se em conta as diferenças de confiabilidade das amostras. Uma alternativa interessante é o favorecimento, por meio da escolha conveniente destes pesos, de amostras mais recentes, o que permite o acompanhamento de processos naturais em evolução.



Figura 3.13 - Aprendizado F-Organizativo Acumulativo.

3. 2. 6. 3. Aprendizado Adaptativo

Os processos de aprendizado Adaptativos implicam em modificações orientadas, ou nos conjuntos difusos, ou nos pesos atribuídos a cada regra associativa, gerada ou existente. As modificações dos conjuntos difusos, no SELF, são a sua distribuição no espaço quantizado de cada variável, ou as formas das funções de pertinência associadas a estes conjuntos.

Estes processos são implementados com o nome de processos Proto-Adaptativos, Tipo-Adaptativos e Peso-Adaptativos, sendo que todos 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 quadráticos. Esta função-objetivo tem desvantagens, em relação à dos desvios absolutos, por exemplo, uma vez que pode favorecer excessivamente o ajuste a valores altos. Porém, pretende-se utilizar o SELF, primeiramente, para o ajuste de cheias, para o qual este critério é conveniente.

Em todos os procedimentos Adaptativos, pode-se optar pela adaptação simples, na qual as regras existentes não são alteradas nem complementadas, ou pela execução concomitante de novo aprendizado Organizativo. Estas opções correspondem, respectivamente, aos Objetivos “Manter Regras” e “Refazer”, sendo que, neste último caso, é importante que o processo Organizativo implícito não seja excessivamente dispendioso em termos de consumo de tempo.

O processo Proto-Adaptativo consiste na procura de uma distribuição melhorada (porém, não necessariamente ótima) para os conjuntos difusos de uma variável escolhida, ou de todas as variáveis, a partir de uma configuração inicial.

Como trata-se de um processo por tentativas muito lento, devido à imensa quantidade de cálculos efetuada, limitou-se as pesquisas a três iterações, sendo que, em cada uma delas é experimentada a variação de cada protótipo, de cada conjunto difuso, da variável ou de cada variável envolvida, conforme descrito na figura 3.14.

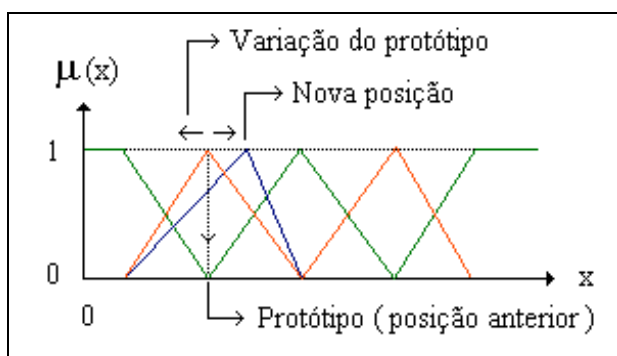


Figura 3.14 - Variação dos protótipos.

A pesquisa univariacional é executada, para a posição do valor de referência de um conjunto difuso, sendo que a sensibilidade para as tentativas é de 1/20 das distâncias entre os protótipos adjacentes. O menor somatório de desvios quadráticos verificado determina a nova posição do protótipo, passando-se então à pesquisa do próximo conjunto, da mesma ou de outra variável, se for o caso.

A investigação dos tipos (ou melhor, das formas das funções de pertinência dos conjuntos difusos) pode, igualmente, ser feita (figura 3.15) para todas as variáveis envolvidas ou para apenas uma, resultante da escolha do usuário.



Figura 3.15 - Aprendizado Tipo-Adaptativo : Uma variável.

Pesquisa-se cada um dos três tipos, aplicado uniformemente para todas as variáveis, ou para a variável escolhida, de cada vez. Para cada tipo, faz-se a geração de regras associativas pelo procedimento Organizativo, e uma simulação com obtenção do desvio quadrático, utilizado para as comparações.

Este procedimento, chamado de Tipo-Adaptativo no SELF, não é um procedimento de otimização por aproximação, mas uma busca exaustiva da melhor configuração, embora limitado às condições especificadas.

A experimentação automática de todas as combinações possíveis não é interessante, tendo-se em conta os ganhos limitados obtidos nas análises efetuadas, e o tempo previsto de processamento resultante do grande número de possibilidades. Por exemplo, considerando-se cinco variáveis explicativas e uma explicada, são 729 combinações para as três funções de pertinência possíveis.

Finalmente, no processo Peso-Adaptativo, determina-se o valor de cada peso, associado a cada regra da biblioteca de conhecimentos. O procedimento consiste na busca de uma ponderação mais eficiente para cada regra, por simulação com o cálculo da função-objetivo.

Neste caso, os pesos funcionam como parâmetros os quais podem alterar a qualidade dos resultados, perdendo, portanto, o caráter de medida da confiabilidade ou importância da regra. Evidentemente, o processo não verifica todas as combinações possíveis, mas consegue-se melhorar estes parâmetros, em iterações sucessivas.

O SELF executa automaticamente, a cada chamada, 3 iterações, a partir das quais não revelaram-se, nos testes efetuados, modificações sensíveis. O espaçamento para a pesquisa, de 5%, revelou-se plenamente satisfatório.

Na medida em que os pesos calculados pelo processo Peso-Adaptativo revelem-se produtivos, em relação à alternativa anterior, pode ser interessante, futuramente, incorporá-los como procedimento padrão à conclusão dos demais processos Adaptativos e Organizativos. Neste caso, o cálculo das frequências pode continuar sendo feito, concomitantemente, pela utilidade que pode ter na avaliação do grau de ajustamento de cada regra.

3. 3. Os Aspectos Metodológicos da Aplicação

3. 3. 1. Generalidades

Uma vez que o interesse da previsão de cheias é, principalmente, referente a níveis de inundação, e que estes têm uma interpretação imediata, já que representam uma grandeza diretamente reconhecível pelos sentidos humanos, independentemente de instrução técnica, opta-se, entre previsão de descargas ou previsão de níveis, por esta última.

Teoricamente, o conjunto encadeado de funções, de transformação de chuvas em vazões, mais a transformação de vazões em níveis, pode ser representado diretamente pela transformação de chuvas em níveis. Esta hipótese é adotada, uma vez que, assim, são evitadas as incertezas que seriam incorporadas pelas conversões entre níveis e descargas.

Em modelos de previsão de curto prazo, a qualidade dos resultados aumenta à medida que reduz-se o alcance (τ), principalmente devido à diminuição do espaço de tempo descoberto correspondente ao horizonte da previsão. Também contribui para isso o fato de que os processos não-lineares podem ser mais bem representados por tendências lineares quando o intervalo de tempo é menor.

Por outro lado, enquanto a precisão e a confiabilidade forem aceitáveis, a utilidade do modelo cresce com o aumento do alcance da previsão. A partir de um certo alcance, a previsão inviabiliza-se, pois os fenômenos que afetam os resultados desejados estarão ocorrendo no futuro, entre t e $t + \tau$.

Portanto, um aspecto importante da pesquisa é a investigação da evolução dos resultados com o aumento do alcance da previsão. O alcance máximo que pode ser obtido, com uma dada confiabilidade e precisão, depende do tempo de resposta do sistema e da precisão desejada. A melhor forma de realizar-se esta verificação, embora mais trabalhosa, é o ajuste e a simulação de diversas alternativas.

O uso de séries extensas, ao contrário de eventos isolados, justifica-se, uma vez que, em situações práticas, supõe-se que o operador pode não saber, com antecedência, se está para ocorrer um evento de cheia ou um período de estiagem severa, ou um período normal.

Neste caso, mesmo modelos que apresentaram competência comprovada para previsão de eventos isolados, partindo do pressuposto de que já se sabia que este ocorreria, podem ter pouca utilidade, uma vez que se estaria prevendo apenas a forma do hidrograma. Portanto, é importante a obtenção e sistematização dos dados a serem utilizados na forma de séries temporais de grandes períodos.

Uma vez que insuficiência de recursos técnicos, operacionais e financeiros limitam a capacidade de aquisição em tempo atual de dados para os sistemas, em situações práticas, as pesquisas, em geral, buscam resultados a partir de pequena quantidade de postos pluviométricos. Como consequência, conclusões importantes deixam de ser concretizadas, por conta da imprecisão na estimativa do campo de precipitações sobre a bacia, devido ao número insuficiente de postos e a sua má distribuição.

Neste trabalho, as investigações são efetuadas, inicialmente, contando-se com chuvas representativas obtidas pela média dos totais diários precipitados sobre um número relativamente grande de postos pluviométricos. Após a análise, estuda-se a aplicação prática das técnicas, em situações mais realistas, ou seja, com menor número de estações de aquisição.

A comparação do desempenho dos modelos selecionados, quando são utilizados todos os postos empregados na pesquisa, para previsão, e em situações alternativas, com menor número de estações pluviométricas, requer a utilização de um índice específico para a quantificação da perda de eficiência do modelo, à medida que degrada-se o sistema de aquisição em tempo atual de dados. O coeficiente de eficiência relativa é então modificado, adotando-se o nome de coeficiente de perda de eficiência.

As pesquisas são desenvolvidas em uma seqüência compatível com as características das técnicas empregadas. Em uma primeira etapa, uma técnica de pesquisa hierarquizada é utilizada para a identificação dos modelos, porém com o uso dos recursos mais simples disponíveis para aprendizado.

Então, os recursos mais sofisticados são experimentados, com os modelos definidos anteriormente, resultando nas bibliotecas de conhecimento definitivas, com as quais as previsões destes modelos são comparadas com as dos modelos empíricos lineares, tanto na forma pontual quanto de categorias. Os modelos empíricos lineares são ajustados utilizando-se as mesmas informações dos modelos baseados no sistema especialista, para comparação da eficiência em situações idênticas.

Finalmente, são feitas especulações sobre o uso dos modelos desenvolvidos com lógica difusa, para situações em que as precipitações representativas sobre a bacia são obtidas a partir de número progressivamente reduzido de postos de aquisição pluviométrica.

3.3.2. A Identificação dos Modelos

A identificação dos modelos, neste trabalho, consiste na investigação dos grupos de variáveis, bem como do número de conjuntos difusos adotados para estas, que proporcionam respostas mais eficientes à previsão.

Para efeito destas aplicações, emprega-se o termo variável de forma particularizada. No caso de um modelo autoregressivo com duas componentes, por exemplo, cada componente é interpretada como sendo uma variável, podendo ter atribuída quantização difusa diferente.

Com o objetivo de evitar-se danos à interpretação, causados por falso conhecimento, as pesquisas são executadas sempre com estatísticas resultantes da verificação, com séries diferentes das utilizadas no aprendizado.

A técnica de aprendizado utilizada, na identificação, resume-se ao do tipo S-Organizativo, sendo as técnicas progressivamente mais refinadas reservadas para os estudos posteriores, com a finalidade de melhoramento dos modelos escolhidos.

Em uma primeira etapa da identificação, utiliza-se a pesquisa hierarquizada (ou seja, realiza-se a pesquisa com testes, primeiramente, das estruturas mais simples, com incremento progressivo) para a verificação dos grupos de variáveis que são mais bem sucedidos, a partir de configurações arbitradas para a quantização difusa, com respectivas funções de pertinência.

É testada, em primeiro lugar, a qualidade das previsões que seriam obtidas considerando-se como antecedentes apenas os próprios níveis passados e presente no posto de controle, para a previsão dos níveis futuros. A situação mais simples possível é a previsão com base unicamente nos níveis atuais (tempo t). Os níveis antecedentes são acrescidos gradualmente ($t-1$, $t-2$, etc.), até que não haja melhora significativa dos resultados.

Quando concluída a pesquisa do número mais conveniente de componentes da série de níveis, inicia-se investigação semelhante para os dados de chuva, acrescentando-se aos antecedentes resultantes da análise anterior, progressivamente, as componentes de precipitações (P_t, P_{t-1} , etc.), até que nova componente não resulte em melhoramento.

A ordem de investigação é importante, uma vez que cada modelo pode complementar suas regras com as do modelo anterior, se necessário, para suprir falta de conhecimento. Por exemplo, as duas regras reproduzidas na figura 3.16 representam a última regra do modelo com três antecedentes, o AR(3), e a primeira do modelo com dois antecedentes, o AR(2), da forma como são dispostas, seqüencialmente, na biblioteca combinada de conhecimentos.




Figura 3.16 – Combinação das regras nos modelos autoregressivos.

Caso a combinação de antecedentes ocorrida não possua pelo menos uma regra associativa correspondente no conjunto de regras do modelo AR(3), o sistema procura uma regra que satisfaça no conjunto seguinte de regras (do modelo AR(2)), desconsiderando, portanto, a última variável, ou seja a última componente autoregressiva.

À medida que aumenta a complexidade do modelo e, portanto, o número possível de combinações de antecedentes, aumenta também o número de regras geradas. Estas podem ser de duas naturezas : As que descrevem as relações lógicas existentes entre as variáveis, e as que descrevem as combinações que são ocorrências específicas das séries utilizadas para o aprendizado.

Quando uma componente adicional não é importante para a construção de regras do primeiro tipo, esta contribui para a construção de regras do segundo tipo, gerando “falso conhecimento”, o qual contribui para erros quando o modelo é aplicado para outras séries. Por isso, o excesso de componentes não apenas deixa de trazer benefícios, mas também pode prejudicar os resultados obtidos na verificação.

Além da verificação do número de componentes de níveis e de chuvas que resultam em respostas mais satisfatórias, pesquisa-se também a alternativa de composição de mais de

uma média de chuvas, as quais passam a representar, separadamente, regiões diferentes da bacia.

Finalmente, após as conclusões sobre que variáveis utilizar, passa-se a investigar, também por tentativas, a melhor configuração para o número de conjuntos difusos de cada variável.

3.3.3. O uso das Técnicas de Aprendizado

Como o aprendizado Adaptativo é, por definição, recomendado para ajuste da quantização difusa (inclusive das funções de pertinência), quando já existe conhecimento qualitativo do funcionamento do sistema, este conhecimento é obtido preliminarmente, sob forma de regras associativas, por meio de aprendizado Organizativo, a partir de configuração arbitrada para os conjuntos difusos das variáveis.

Os procedimentos de aprendizado Organizativo desenvolvidos para geração de regras associativas a partir de registros amostrais constituem-se em recursos para a determinação do conjunto difuso correspondente a cada combinação observada de antecedentes. Uma vez que, no caso de amostras numéricas, os valores freqüentemente estão associados a mais de uma categoria, os conjuntos com menor grau de pertinência (ou conjuntos secundários) também são considerados, com uma ponderação que depende dos graus de pertinência observados.

As diferenças nos dois procedimentos utilizados, o S-Organizativo e o F-Organizativo, são que, no segundo, a cada regra é associada uma ponderação que representa a freqüência de ocorrência do conseqüente adotado, na combinação de antecedentes correspondentes.

Nos métodos tradicionais de aprendizado Organizativo, porém, as regras associativas são derivadas unicamente da maior freqüência observada, para cada combinação de antecedentes ocorrida na amostra.

Portanto, os resultados da simulação com uso das regras provenientes de aprendizado com estes dois procedimentos são comparados, entre si e com uma terceira alternativa, chamada de procedimento S-Organizativo Simplificado. Neste caso, os conjuntos secundários não são considerados para a determinação dos pesos formadores da matriz cognitiva.

Tanto o procedimento Tipo-Adaptativo quanto o Proto-Adaptativo são utilizados, separadamente, para cada variável. O procedimento Proto-Adaptativo é refeito, a cada alternativa experimentada para o extremo superior das chuvas, cujo limite superior (que havia sido arbitrado inicialmente) é pesquisado até encontrar-se a localização mais adequada.

Uma seqüência alternada de operações, com utilização do procedimento Tipo-Adaptativo, aplicado separadamente para cada variável, seguido do procedimento Proto-

Adaptativo, também aplicado separadamente para cada variável é utilizado, repetidamente, até que, entre uma iteração e outra, não haja modificação dos protótipos e das funções de pertinência.

Então, o procedimento Peso-Adaptativo é utilizado, obtendo-se os resultados finais. O conjunto de operações realizadas com os procedimentos de aprendizado Adaptativo é ilustrado na figura 3.17.

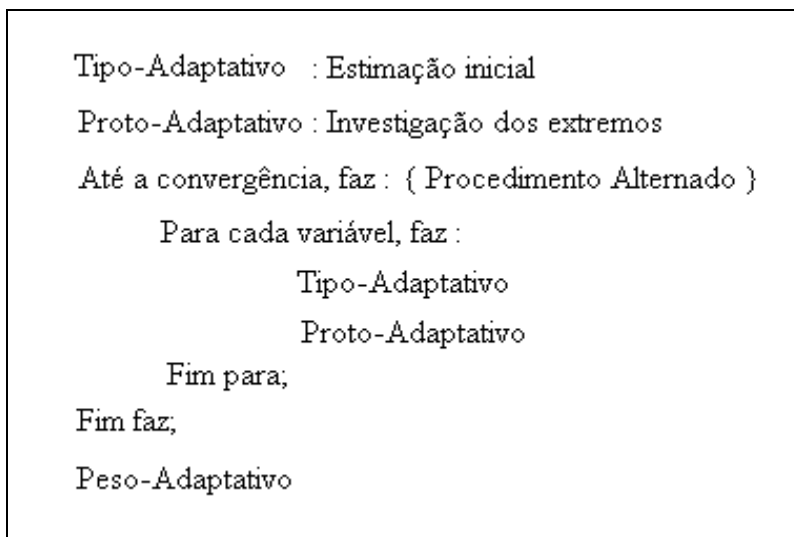


Figura 3.17 – Uso dos procedimentos Adaptativos.

3.3.4. As Previsões Categorizadas

Os procedimentos Adaptativos produzem alterações nos conjuntos difusos, de forma que cada modelo, representado pela respectiva biblioteca de conhecimentos, passa a possuir uma definição própria para estes.

Como consequência, uma previsão em determinada categoria possui significados diferentes em função do alcance a que se destina, podendo gerar confusões ao ser divulgada.

Uma solução adequada para este inconveniente é a definição de uma escala fixa de categorias da variável explicada, independentemente das quantizações particulares de cada modelo. O valor previsto é submetido a esta escala, a qual transforma a previsão, da forma numérica para a forma de conjuntos difusos, principal e, se houver, secundário, com os respectivos graus de pertinência (figura 3.18).

Um mecanismo, ou sistema para conversão, pode ser construído no próprio SELF, sob a forma de uma biblioteca específica de conhecimentos. Este sistema compõe-se de duas variáveis igualmente quantizadas, uma explicativa e outra explicada, ambas representativas, no caso, dos níveis fluviais.

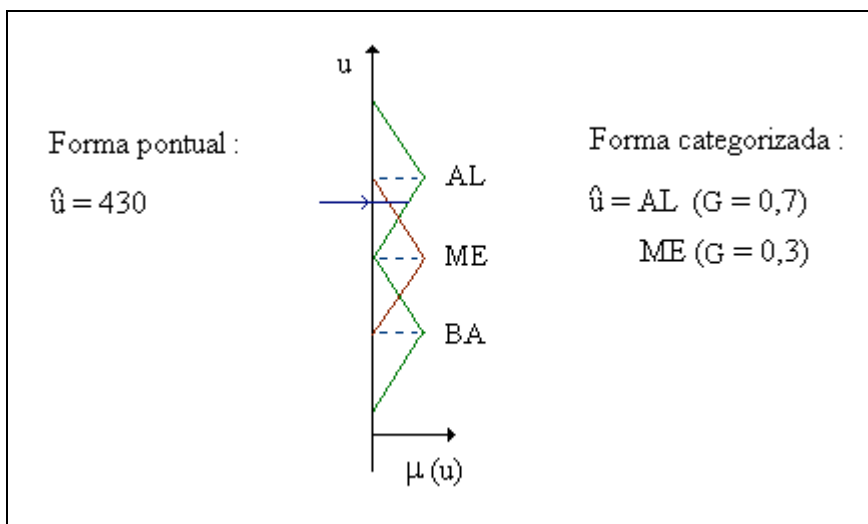


Figura 3.18 – Transformação para conjuntos difusos : Exemplo.

Os conjuntos de regras associativas correspondem a relações biunívocas entre os conjuntos difusos destas duas variáveis. Estas relações transformam os valores das previsões pontuais (dados de entrada) nelas mesmas (valores de saída), porém os resultados são apresentados sob a forma dos conjuntos difusos com os graus de pertinência correspondentes. Na figura 3.19, tem-se a representação de parte deste mecanismo, para um exemplo de entrada numérica (\hat{u}).

As categorias utilizadas podem estar associadas à noção existente de níveis ALTOS, MÉDIOS, BAIXOS, etc.. Porém, uma alternativa interessante é supor-se que existe uma espécie de exigência de projeto. Por exemplo : deseja-se estabelecer as categorias de níveis para as quais é possível acertar-se, com uma determinada frequência, as previsões com determinado alcance, para efeito de divulgação e tomada de decisões.

Neste caso, o objetivo pode ser obtido por tentativas, utilizando-se, como simulador, o mecanismo descrito anteriormente, ao qual são submetidas diversas alternativas de quantização. As frequências de acerto, sob forma dos coeficientes de agrupamento, são calculadas pelo SELF, e apresentadas ao final da simulação. Adota-se, então, a quantização difusa mais detalhada possível, que atende às exigências formuladas.

Um aspecto importante é que, com este mecanismo, são possíveis previsões mais confiáveis, por categorias, sem que sejam alteradas as precisões das estimativas numéricas originais. Outro ponto relevante é que previsões pontuais de qualquer origem (modelos conceituais ou empíricos) podem ser convertidas para a forma categorizada.

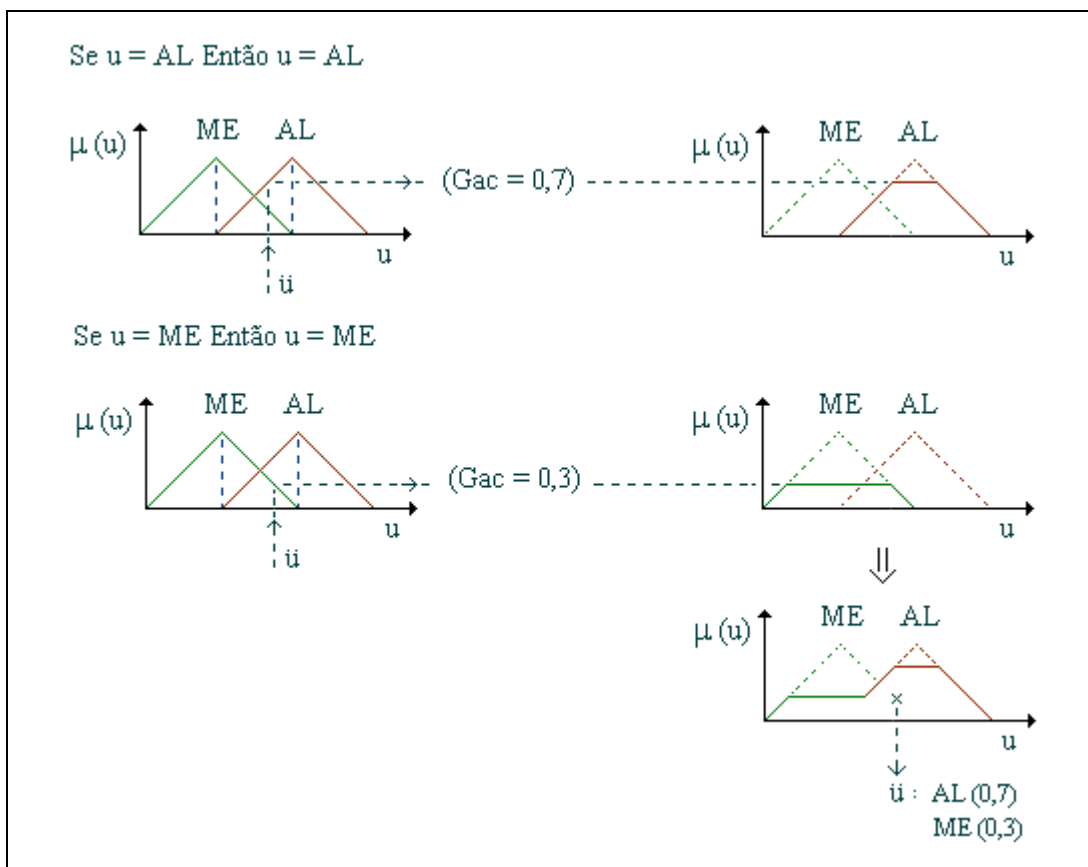


Figura 3.19 – Mecanismo de transformação através do SELF.

Uma categorização específica, então, pode ser adotada para servir de referência, talvez permanentemente. A escolha desta depende dos alcances para os quais os agentes responsáveis consideram mais importante manter-se uma certa frequência de acertos, da utilidade da previsão, tendo-se em conta a amplitude das categorias resultantes, e do critério escolhido para a estimativa da confiabilidade das previsões.

3.3.5. Os Modelos Empíricos Lineares

Existe uma forte analogia entre os modelos empíricos lineares e os modelos que são representados pelo SELF, no que diz respeito à escolha e identificação das variáveis e à capacidade de adaptação às novas situações. Neste item, porém, são evidenciadas também as diferenças de concepção, uma vez que estas são, teoricamente, responsáveis pelas possíveis diferenças das respostas fornecidas.

Os modelos empíricos são funções contínuas, capazes de fornecer respostas em todo o domínio das variáveis envolvidas, sendo favorecidos pelos pequenos alcances, nos quais as aproximações realizadas (como a linearidade) podem ser aceitas.

Este tipo de modelos frequentemente aparece, sob denominações variadas, na literatura especializada em previsões em tempo atual, apresentando, geralmente, melhor desempenho que outras abordagens, especialmente se utilizadas técnicas recursivas de calibragem.

É possível, assim como para qualquer forma de previsão numérica, conforme demonstrado anteriormente, a conversão das respostas destes modelos para a forma categorizada de apresentação e interpretação.

Os modelos que são inteiramente concebidos na forma de sistemas especialistas, por sua vez, não contém equações, mas sim proposições lógicas que associam conjuntos difusos nos quais são quantizadas as variáveis, explicativas e explicada, participantes. As previsões sob forma de categorias difusas, neste caso, são uma consequência natural das características dos sistemas especialistas e da lógica difusa.

Os coeficientes de agrupamento, ou seja, a frequência de ocorrências totais (Fot), a frequência de ocorrências parciais (Fop) e a frequência de ocorrências combinadas (Foc), são utilizadas para quantificar os acertos das previsões sob forma de categorias difusas, tanto resultantes dos modelos empíricos lineares quanto dos sistemas especialistas, com objetivo de comparação da eficiência dos modelos, neste aspecto.

A recessão está relacionada ao fenômeno de esvaziamento da bacia e dos canais fluviais, ocorrendo de forma gradual e mais previsível que a ascensão. Por isso, geralmente, os maiores erros dos modelos de previsão em tempo atual ocorrem, principalmente, nos períodos ascendentes.

É conveniente a comparação do desempenho de modelos competidores em faixas de ocorrência. Uma vez que as faixas de ascensão são os períodos mais críticos e de difícil previsão, são analisados os desempenhos, tanto no ajuste quanto na verificação, para estas faixas específicas. Esta análise diferenciada é feita com base nos coeficientes parciais de desempenho, os quais são as mesmas estatísticas utilizadas normalmente, sendo porém obtidos limitando-se os somatórios correspondentes aos períodos específicos desejados.

Os ajustes e simulações de modelos empíricos lineares, com ou sem adaptação em tempo atual dos parâmetros, são efetuados com o uso do ARMEL (Ajuste Recursivo de Modelos Empíricos Lineares), o qual é um aplicativo desenvolvido para estas finalidades, e cuja técnica de ajuste é a dos mínimos quadrados recursivos (Young, 1974).

Os recursos matemáticos do ARMEL não são inéditos, embora o mesmo componha um ambiente confortável e conveniente para a realização dos ajustes e das verificações, com ou sem recursividade, necessárias para a avaliação da qualidade das previsões.

3.3.6. A Redução da Rede de Aquisição

Embora seja importante uma representação suficientemente completa do campo de precipitações sobre a bacia, um grande número de postos de aquisição de dados pode não ser praticável, tendo-se em conta a existência de escassez de recursos tecnológicos e, principalmente, financeiros. Portanto, é importante que seja verificada a qualidade dos resultados em função do número de postos pluviométricos utilizados.

O emprego dos modelos, cujo aprendizado foi efetuado a partir de variáveis que representam determinado número de postos pluviométricos, para operação com variáveis correspondentes que representam um número menor destes postos, resulta em aumento da magnitude dos erros. O acréscimo nos erros possui, principalmente, duas naturezas distintas :

- Erros devidos às modificações de características das variáveis que representam as chuvas ocorridas;
- Erros devidos à redução da representatividade dos totais pluviométricos médios utilizados, como consequência da redução do número de amostras empregadas para cálculo da média.

À medida que seja possível a modificação dos conjuntos difusos do sistema, por um procedimento Adaptativo, para compensação das alterações das variáveis que representam as chuvas, consegue-se sua correção. Os erros que permanecem, portanto, podem ser considerados, a grosso modo, resultantes da segunda fonte identificada.

Uma vez que a análise planejada contempla a investigação do funcionamento do sistema de previsão com progressiva redução dos postos de aquisição pluviométrica, é importante a quantificação relativa das diversas situações.

O uso do coeficiente de eficiência relativa pode revelar o quanto, em termos percentuais, um modelo explica melhor do que outro a variância das observações. Deseja-se saber, porém, o quanto os resultados das previsões ficam piores, com a redução progressiva dos postos pluviométricos. Pode-se alterar ligeiramente a fórmula do coeficiente de eficiência relativa, para representar, analogamente, a perda de eficiência (Pe), resultando em :

$$Pe = \sum_t (\hat{u}_t - u_t) / \sum_t (\hat{u}_t - u_t) - 1, \quad (3.1)$$

onde \hat{u}_t e u_t representam os valores previstos para, respectivamente, o modelo nas condições atuais e nas condições anteriores, com o qual deseja-se efetuar a comparação.

4. Aplicação e Resultados

4.1. Considerações Gerais

Algumas características gerais do sistema são resumidas, a partir do relatório técnico da CPRM para a bacia (Pedrollo, M., 1997). A bacia hidrográfica do rio Camaquã (figura 4.1) tem forma alongada, estando compreendida entre as latitudes 30°30' e 31°15' S e longitude de 51°45' e 54°30' WGR, nas regiões geomorfológicas do Escudo Cristalino e da Planície Costeira. Nas cabeceiras, em locais mais íngremes, predominam solos litólicos, pouco desenvolvidos e de pequena espessura que recobrem diretamente a rocha, altamente suscetíveis à erosão. Ocorre uma transição gradativa, ao longo do curso do rio, aparecendo, no baixo curso, solos hidromórficos, com textura variável, de argilosa a arenosa.

O clima do Rio Grande do Sul é subtropical, do tipo mesotérmico superúmido, sem ocorrência de período seco, sendo bastante homogêneo. As massas polares têm participação importante na circulação regional durante todo o ano, embora no inverno sejam mais intensas, mais numerosas e mais duradouras.

As constantes invasões, em qualquer época do ano, determinando bruscas mudanças de tempo, constituem o traço climático marcante da região, havendo uma notável regularidade no regime de chuvas, com leve tendência para a ocorrência de máximos em julho (inverno), e mínimos de dezembro a março (verão).

Entre os postos hidrológicos existentes, destaca-se o de Passo do Mendonça, o qual possui registrador para precipitações e medição de descargas, sendo também sedimentométrico. Este posto controla uma área de 15543 km², o que constitui quase toda a área da bacia do Camaquã, e está fora da influência do remanso da Lagoa dos Patos.

Tendo-se em conta estas características, este posto é escolhido para testes das metodologias propostas. Os níveis observados apresentam variação entre 0 e 800 cm, enquanto que as descargas, entre 0 e 5000 m³/s.

Uma vez que existe interesse, devido às dimensões da bacia, em previsões com alcances de 12 horas ou mais, e que não pode-se contar, ainda, com séries extensas de linigramas digitalizados, opta-se por trabalhar com séries de níveis de caderneta, de 07:00 e 17:00 horas, os quais estão disponíveis, digitados no MSDHD (Microssistema de Dados Hidrológicos do DNAEE/ANEEL), desde 01 de janeiro de 1991.

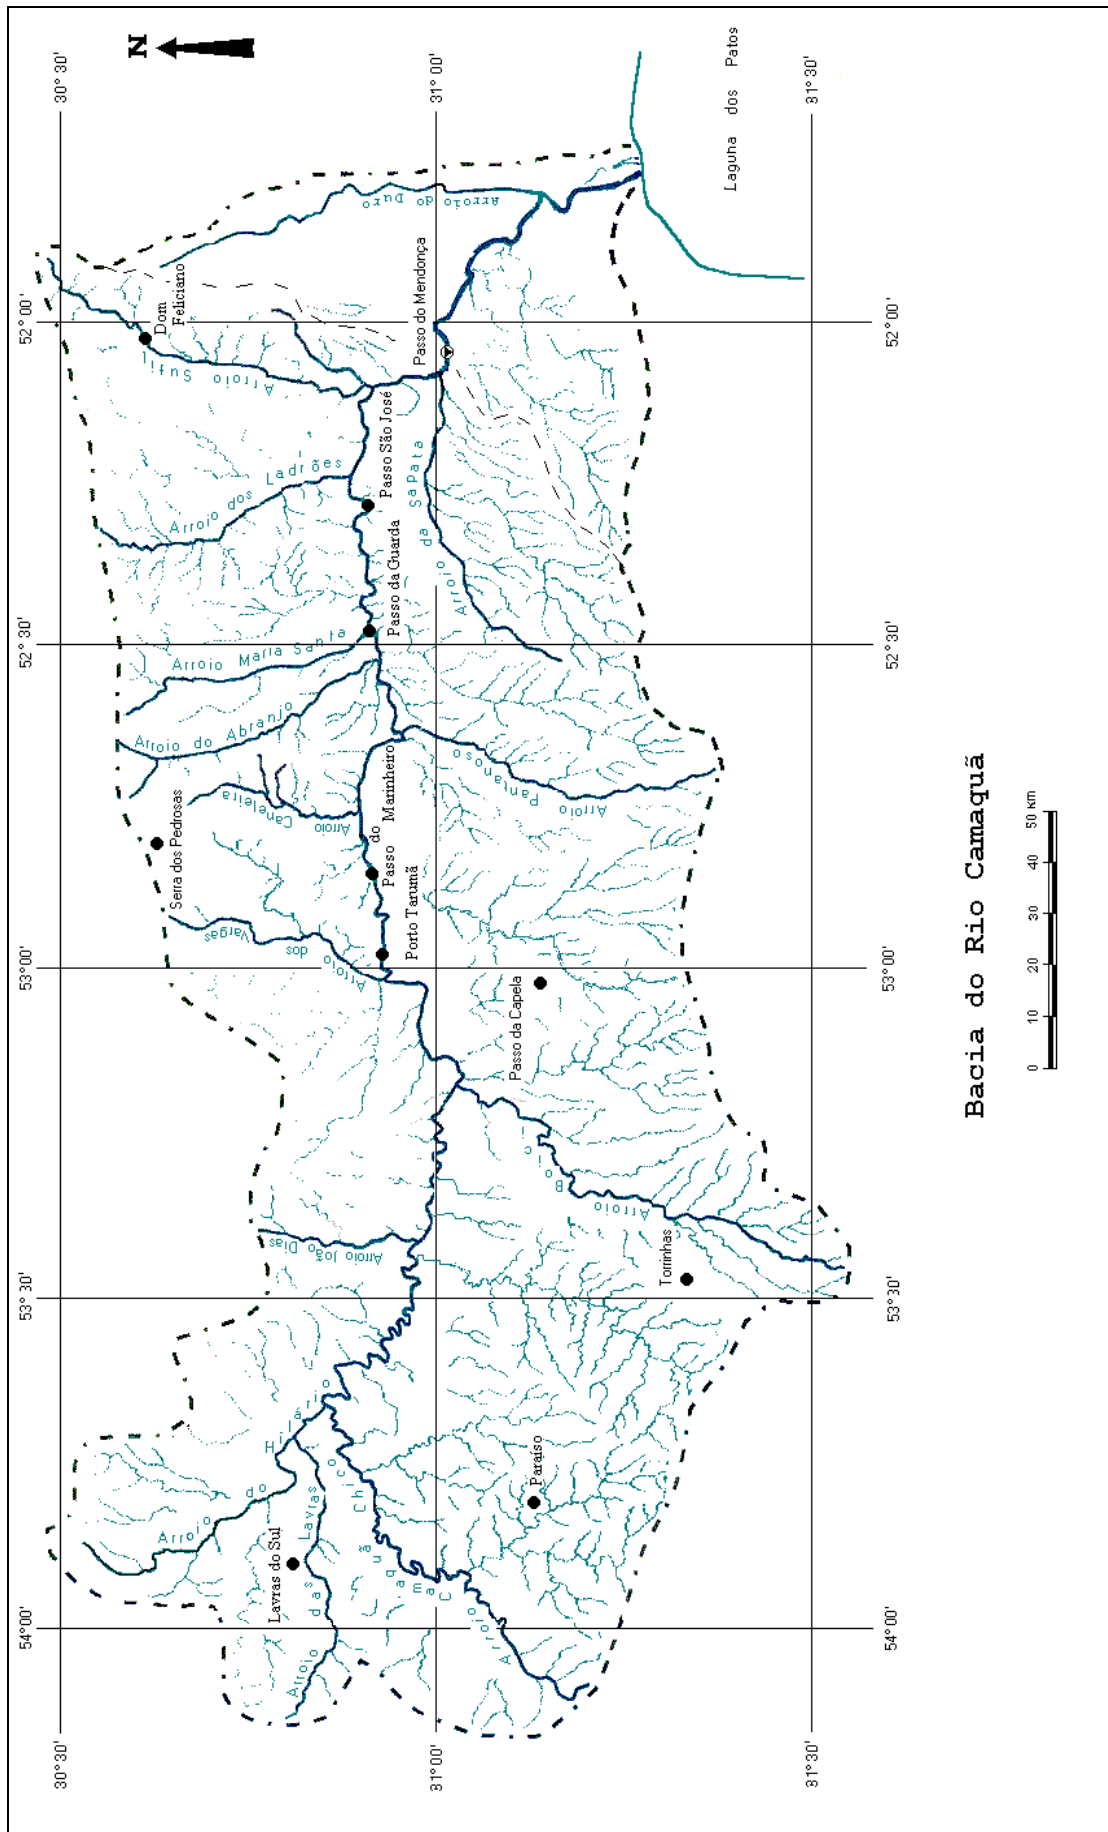


Figura 4.1 - Bacia do Rio Camaquã.

A disponibilidade de dupla leitura de níveis, portanto, é o principal fator condicionante do período de estudo, o qual compreende o intervalo de 01 de janeiro de 1991 a 12 de dezembro de 1999, com falhas entre 05 e 22 de novembro de 1995 e entre 02 de janeiro e 23 de abril de 1997.

Dois períodos, um para ajuste ou aprendizado amostral e outro para verificação são estabelecidos. O primeiro destes períodos compreende o intervalo de 01 de janeiro de 1991 a 01 de janeiro de 1997. O intervalo restante (de 24 de abril de 1997 a 31 de dezembro de 1999) compreende o período destinado à verificação dos modelos. O período selecionado para o ajuste é propositalmente maior, devido às dificuldades existentes para aquisição suficiente de conhecimentos a partir de amostras disponíveis, geralmente exíguas em situações práticas. Na tabela 4.1, apresentam-se algumas características descritivas dos níveis, nos períodos estabelecidos.

Tabela 4.1 - Estatísticas básicas dos níveis amostrais.

Objetivo	Período	Número de Registros	Mínimos (cm)	Médios (cm)	Máximos (cm)
Ajuste	01/01/1991 a 01/01/1997	2175	78	212	797
Verificação	24/04/1997 a 31/12/1999	982	66	251	791

A faixa de níveis (u) com maiores frequências ocorre em torno de 100 cm, para os dois períodos, sendo de 180 cm o nível com 50% de frequência de excedência ($F(u \geq 180 \text{ cm}) = 50\%$), para os dados amostrais utilizados, segundo a curva de permanências (figura 4.2).




Figura 4.2 – Curva de permanências de níveis.

A natureza dos dados disponíveis, bem como as possibilidades oferecidas pela complexidade do problema resultam na opção pela pesquisa das previsões possíveis com base nas precipitações.

Tendo-se em conta que chuvas possuem variabilidade espacial, e que existem possíveis erros de observação ou leitura que podem comprometer as análises, é importante a utilização de séries de chuvas cujos dados resultam da composição por diversos postos de medição.

As onze estações pluviométricas (tabela 4.2) são adotadas, com base nos critérios de existência e disponibilidade dos dados (totais acumulados às 07:00 horas) em todo o período pesquisado, e tendo-se em conta, também, a distribuição espacial relativamente abrangente dos postos na bacia.

Tabela 4.2 - Postos pluviométricos utilizados.

Nome	Código ANEEL	Altitude (m)	Latitude	Longitude	Entidade
Lavras do Sul	03053007	300	30°48'	53°54'	CEEE
Paraíso	03153003	368	31°13'	53°51'	CEEE
Torrinhas	03153017	420	31° 18'	53°29'	ANEEL
Passo da Capela	03153006	120	31°08'	53°03'	ANEEL
Serra dos Pedrosas	03052012	400	30°37'	52°48'	ANEEL
Porto Tarumã	03052010	80	30°55'	52°57'	CEEE
Passo do Marinheiro	03052008	75	30°54'	52°49'	CEEE
Passo da Guarda	03052007	60	30°54'	52°27'	CEEE
Passo São José	03052009	50	30°53'	52°14'	CEEE
Dom Feliciano	03052004	100	30°42'	52°04'	CEEE
Passo do Mendonça	03152011	40	31°00'	52°02'	ANEEL

Adota-se, para estes estudos, chuvas representativas compostas das médias aritméticas dos totais acumulados diariamente. Duas alternativas são consideradas para o cálculo de séries de chuvas representativas.

No primeiro caso, deseja-se investigar separadamente os efeitos das contribuições de oeste e de leste da bacia, para verificar-se a influência dos tempos de deslocamento dos

volumes gerados. Portanto, são calculadas duas séries de precipitações representativas. As contribuições de oeste são calculadas a partir dos quatro postos localizados a ocidente da longitude de 53°, e as de leste, com os demais postos.

No segundo caso, é calculada uma única série, composta das médias aritméticas dos totais acumulados diariamente de todas as onze estações. As chuvas assim constituídas, são dados de entrada para a modelagem chuva-nível, para previsão em tempo atual com os recursos experimentados.

Os níveis previstos, como consequência, são importantes, se suficientemente confiáveis, para divulgação e acompanhamento, uma vez que a natureza desta informação faz parte da experiência sensível humana, dispensando conhecimentos técnicos específicos, além de ser parâmetro para a eventual tomada de decisões, tanto pessoal quanto pública.

A indisponibilidade de séries digitalizadas, especialmente de chuvas, constitui uma limitação importante, no sentido de condicionar a escolha do tempo atual para execução das previsões. Uma vez que as observações de totais pluviométricos acumulados diariamente são feitas às 07:00 horas, e que o máximo proveito das previsões é obtido quando o tempo atual coincide com a obtenção da última informação necessária, adota-se esta hora para a execução das previsões, independentemente de cada alcance considerado.

Quatro alcances de previsão são pesquisados, ou seja, $\frac{1}{2}$ dia, 1 dia, 1 $\frac{1}{2}$ dias e 2 dias. Alcances maiores não são, por enquanto, cogitados, devido ao decaimento progressivo da qualidade dos resultados, e à utilidade duvidosa.

As previsões são efetuadas, portanto, para às 17:00 horas do mesmo dia, ou para às 07:00 horas ou 17:00 horas do dia seguinte, ou ainda para às 07:00 horas do próximo dia, conforme o alcance seja, respectivamente, para $\frac{1}{2}$, 1, 1 $\frac{1}{2}$ ou 2 dias. Portanto, $\frac{1}{2}$ dia significa, na verdade, 10 horas, e 1 $\frac{1}{2}$ dia, 34 horas de alcance.

4.2. A Identificação dos Modelos

O coeficiente de eficiência utilizado para as comparações, com o objetivo de identificação dos modelos mais eficientes, é o Erro Padrão (Ep), expresso em cm, o qual transmite a noção da ordem de grandeza dos erros.

Os níveis são quantizados em nove conjuntos difusos, cujos protótipos variam de 0 a 800 cm, com funções de pertinência triangulares.

As chuvas são categorizadas em três conjuntos difusos, com protótipos correspondentes de 0, 30 e 60 mm, e funções de pertinência sigmoidais.

Os conjuntos difusos são, inicialmente, arbitrados, tendo os protótipos extremos sido escolhidos após inspeção visual das séries respectivas.

Na tabela 4.3, apresentam-se as estatísticas obtidas para os modelos autoregressivos testados, com até quatro componentes ($p = 4$), sendo a primeira o nível atual (07:00 horas de “hoje”), a segunda e a terceira os níveis de “ontem” (respectivamente, às 17:00 e às 07:00 horas), e assim, regressivamente.

Tabela 4.3 – Identificação dos modelos autoregressivos : Ep (cm).

Alcance (dias) :	$\frac{1}{2}$	1	1 $\frac{1}{2}$	2
(p) ↓				
(1)	15,17	37,89	48,44	85,22
(2)	17,90	39,03	51,90	66,00
(3)	19,12	39,54	49,62	63,75
(4)	23,23	43,74	52,73	65,09

Para todos os alcances, observa-se que os melhores resultados correspondem ao uso de apenas uma componente autoregressiva, o que significa que a captação de tendências de crescimento ou recessão induz mais a erros do que a acertos. A exceção é o alcance de dois dias, possivelmente porque o modelo de persistência, para este caso, é ainda pior.

A identificação da influência das chuvas parciais (contribuições dos setores de Leste e de Oeste da bacia), é analisada, separada e conjuntamente, sendo apresentados os resultados, em termos do erro padrão, na tabela 4.4. O número de componentes autoregressivas (p) é sempre 1, e “q” e “r” são o número de componentes das contribuições de Leste e Oeste, respectivamente.

Observa-se que a utilização de duas variáveis para cada contribuição (Leste e Oeste), constituiu-se na melhor alternativa para todos os alcances, com exceção de $\frac{1}{2}$ dia, quando o acréscimo de variáveis sempre conduz a resultados piores.

Em todos os casos, as contribuições de Leste são mais importantes que as de Oeste. Contudo, observa-se que, à medida que aumenta o alcance da previsão, os modelos que utilizam-se de ambas as contribuições tornam-se melhores do que os que utilizam-se apenas das contribuições de Leste. Isto possui uma certa coerência, pois indica que existe um atraso para que façam-se sentir os efeitos das chuvas na porção ocidental da bacia.

Tabela 4.4 – Identificação dos modelos com chuvas parciais : Ep (cm).

Contribuições	Alcance (dias) :	$\frac{1}{2}$	1	1 $\frac{1}{2}$	2
	(p, q, r) ↓				
	(1, 1, 0)	16,45	32,40	40,26	57,17
Leste	(1, 2, 0)	18,23	28,97	37,28	52,29
	(1, 3, 0)	19,22	30,97	39,21	58,51
	(1, 0, 1)	17,60	34,41	45,33	59,21
Oeste	(1, 0, 2)	18,17	33,41	43,26	57,00
	(1, 0, 3)	18,42	35,97	43,53	63,01
	(1, 1, 1)	17,18	31,27	39,36	63,61
Mistas	(1, 1, 2)	18,66	31,41	39,87	72,25
	(1, 2, 1)	19,17	32,10	39,28	47,84
	(1, 2, 2)	19,11	32,77	37,21	57,60

Na tabela 4.5, são apresentados os erros padrões correspondentes à verificação dos modelos com utilização de séries de chuvas resultantes da média dos totais acumulados diariamente de todos os postos.

Neste caso, “p” (= 1 ou 2) representa o número de componentes autoregressivas e “q” representa o número de componentes dos dados de chuvas, sendo a primeira componente o total diário acumulado no tempo atual, e as outras, os totais diários acumulados nos dias anteriores, seqüencialmente em direção ao passado, e sempre com médias de todos os postos, de leituras tomadas às 07:00 horas.

Modelos com duas componentes autoregressivas são novamente testados, apresentando resultados piores do que os modelos AR(1), para todos os alcances, o que confirma a análise feita inicialmente, que não recomenda mais do que uma componente para modelagem autoregressiva.

O melhor desempenho ocorre com o uso de uma componente a mais, em direção ao passado, em relação ao número de componentes de chuvas utilizado nos modelos com chuvas parciais. Ou seja, três componentes de chuvas para todos os alcances, com exceção do alcance de $\frac{1}{2}$ dia. Este, por sua vez, continua apresentando resultados piores do que os do modelo autoregressivo.

Tabela 4.5 – Identificação de modelos com chuvas totais : Ep (cm).

Alcance (dias) :	½	1	1 ½	2
(p, q) ↓				
(1, 1)	17,05	31,08	39,11	53,74
(1, 2)	16,86	29,53	37,79	59,70
(1, 3)	18,23	28,96	35,79	45,98
(1, 4)	19,23	30,43	36,43	46,09
(2, 1)	17,05	35,97	45,97	52,34
(2, 2)	21,58	33,18	41,52	50,96
(2, 3)	21,08	34,47	40,86	49,71

Uma vez que não houveram ganhos relevantes com a subdivisão das contribuições pluviométricas, decide-se prosseguir as análises para avaliação dos recursos desenvolvidos para o sistema utilizando-se, como ponto de partida, os modelos identificados na tabela 4.5.

A eficiência relativa, $Er_{j/j-1}$ (%), destes modelos em relação aos modelos autoregressivos, ou seja, o quanto de variância estes explicam a mais do que os anteriores, calculada segundo a equação 2.29, resulta em 0%, 41,58%, 45,41% e 47,98%, para os alcances respectivos de ½, 1, 1 ½ e 2 dias.

A variação do número de categorias de chuvas é efetuada com estes modelos, para a investigação da quantização mais adequada, apresentando-se as comparações, do erro padrão e do número de regras resultantes para cada caso, na tabela 4.6. São experimentados dois, três e cinco conjuntos difusos, com protótipos adotados de 0 e 60, para o primeiro caso, 0, 30 e 60 para o segundo, e de 0, 15, 30, 45 e 60 para o terceiro.

Tabela 4.6 – Variação do número de categorias de chuvas.

Alcance (dias) :	½		1		1 ½		2	
Nº de Categorias ↓	Ep (cm)	Nº de regras	Ep (cm)	Nº de regras	Ep (cm)	Nº de regras	Ep (cm)	Nº de regras
2	16,58	29	30,73	41	36,96	41	50,46	41
3	16,86	51	28,96	96	35,79	96	45,98	94
5	19,51	104	31,74	205	39,45	194	50,22	205

Para o alcance de $\frac{1}{2}$ dia, o uso de apenas dois conjuntos difusos para as chuvas só é inferior ao modelo autoregressivo, enquanto que, para os demais alcances, a quantização em três categorias difusas revela-se a melhor opção.

O número de regras geradas cresce em proporção maior do que o refinamento da quantização, tendo sido registradas faltas de conhecimento para todos os alcances, com o uso de cinco conjuntos, com uma falha para $\frac{1}{2}$ e 1 dia de alcance, e três e duas falhas, respectivamente, para alcances de $1\frac{1}{2}$ e 2 dias.

Estas falhas são, automaticamente, supridas com conhecimento proveniente de modelos anteriores (com menor número de variáveis), cujas regras são previamente geradas e incorporadas às regras associativas do modelo atual.

A modificação do número de categorias de níveis, nestes modelos (tabela 4.7), não apresenta surpresas. Observa-se redução no número de regras geradas e redução também na qualidade dos resultados.

Tabela 4.7 – Variação do número de categorias de níveis.

Alcance (dias) :	$\frac{1}{2}$		1		$1\frac{1}{2}$		2	
Nº de Categorias ↓	Ep (cm)	Nº de regras	Ep (cm)	Nº de regras	Ep (cm)	Nº de regras	Ep (cm)	Nº de regras
9	16,86	51	28,96	96	35,79	96	45,98	94
7	20,84	45	34,36	78	38,57	76	50,50	78
5	48,01	35	56,79	66	59,97	66	79,36	66

Os protótipos adotados foram os conjuntos (0, 100, 200, 350, 500, 650, 800), e (0, 200, 400, 600, 800) para, respectivamente, sete e cinco categorias.

4.3. O uso das Técnicas de Aprendizado

Com o objetivo de quantificar os efeitos da capacidade de extração de conhecimentos a partir dos conjuntos secundários, o SELF é, temporariamente, destituído desta habilidade, restando um procedimento simplificado, chamado S-Organizativo Simplificado.

Na tabela 4.8, apresenta-se a comparação, em função do erro padrão, para o ajuste e para a verificação, e para cada alcance, do desempenho dos procedimentos S-Organizativo simplificado, S-Organizativo completo, e F-Organizativo.

Tabela 4.8 – Desempenho dos procedimentos do Aprendizado Organizativo : Ep (cm).

Alcance (dias) :	½		1		1 ½		2	
Procedimento	Ajuste	Verif.	Ajuste	Verif.	Ajuste	Verif.	Ajuste	Verif.
Simplificado	13,65	16,96	23,63	29,44	28,86	36,13	42,65	53,93
S-Organizativo	13,39	16,86	23,39	28,96	28,97	35,79	38,87	45,98
F-Organizativo	13,56	17,05	23,50	28,68	28,69	35,59	38,94	45,75

Observa-se melhora do desempenho dos modelos, acompanhando o aumento da complexidade do método de aprendizado, para todos os casos, com exceção do alcance de ½ dia, que piora um pouco com o recurso F-Organizativo.

O número de regras associativas geradas pelos procedimentos independe do alcance, sendo de 78 e 96, respectivamente, para o método simplificado e para os demais. No caso do alcance de ½ dia, porém, o modelo utilizado adota número diferente de componentes de precipitações (ou seja, duas), resultando em 48 e 51 os números respectivos de regras geradas.

O aumento do número de regras associativas obtido no procedimento S-Organizativo completo, em relação ao número de regras obtido com a destituição do recurso de extração de regras amostrais também dos conjuntos secundários (S-Organizativo simplificado), é perceptível.

A qualidade dos resultados das previsões, porém, não parece melhorar na mesma proporção, o que pode ser indício de que as regras associativas mais importantes já estão presentes na biblioteca de conhecimentos obtida com o procedimento simplificado.

Embora esta não tenha sido a oportunidade mais reveladora, principalmente porque não aconteceram casos de falta de conhecimento a serem resolvidos pelo acréscimo de algumas regras, a melhora, ainda que modesta, na capacidade de aquisição de conhecimento e no desempenho dos modelos, confirma a utilidade do recurso de aprendizado a partir de amostras utilizando-se também as associações sugeridas pelos conjuntos secundários.

A melhora no desempenho dos modelos, com uso do aprendizado F-Organizativo, por sua vez, é pouco relevante. Porém, este recurso não implica em custos adicionais, em termos de complexidade de uso ou do número de regras associativas, adotando-se, portanto, os modelos resultantes, até então, para o prosseguimento das pesquisas.

A seqüência utilizada para o uso do aprendizado Adaptativo, por sua vez, permite a apreciação da importância adquirida por cada recurso desenvolvido, ao longo da pesquisa. Na tabela 4.9, pode-se examinar os progressos obtidos, comparando-se os resultados das

simulações de previsão, tanto do período de Ajuste (utilizado para o aprendizado), como da Verificação.

Tabela 4.9 – Desempenho dos procedimentos do Aprendizado Adaptativo : Ep (cm).

Alcance (dias) :	½		1		1 ½		2	
Procedimento	Ajuste	Verif.	Ajuste	Verif.	Ajuste	Verif.	Ajuste	Verif.
Tipo-Adaptativo	16,52	13,63	28,32	23,70	34,61	29,15	45,51	39,42
Proto-Adaptativo	15,00	14,88	27,74	23,41	33,46	30,15	43,98	40,63
Alternado	14,33	13,79	26,05	23,19	31,38	29,29	42,40	39,40
Peso-Adaptativo	13,07	13,14	23,55	21,98	29,19	28,04	40,33	39,09

O procedimento Tipo-Adaptativo produz algumas melhoras, porém reduzidas, nos valores do erro padrão, para todos os alcances considerados, o que ocorre após algumas mudanças das funções de pertinência :

- Dos níveis previstos, no modelo com alcance de ½ dia, de triangular para sigmoidal;
- Das chuvas P_{t-1} e P_{t-2} , nos modelos com alcances de 1 e 1 ½ dias, de sigmoidal para triangular;
- Das chuvas P_{t-1} , no modelo com alcance de 2 dias, de sigmoidal para triangular.

O procedimento Proto-Adaptativo é utilizado para a procura de melhores protótipos internos, a cada alternativa escolhida para os protótipos externos das chuvas. Os progressos são mais significativos, resultando em precipitações com protótipos extremos de 95, 65, 80 e 85 mm, para, respectivamente, alcances de ½, 1, 1 ½ e 2 dias.

O recurso de alternância iterativa entre os procedimentos Tipo-Adaptativo e Proto-Adaptativo resulta em progressos ainda maiores, desta vez obtendo-se avanços até mesmo no modelo chuva-nível para ½ dia de alcance.

Este processo iterativo define a configuração final para os conjuntos difusos, sejam os valores assumidos pelos protótipos correspondentes, sejam as funções de pertinência a estes conjuntos. Finalmente, o procedimento Peso-Adaptativo encerra o processo de aprendizado, com os progressos mais significativos.

Na tabela 4.10, o coeficiente de eficiência relativo, $Er_{j/j-1}$ (%), é utilizado para apresentar a evolução da variância explicada, ao longo das pesquisas. Compara-se a eficiência do modelo final, após o aprendizado Peso-Adaptativo, com os resultados obtidos com o método imediatamente anterior (alternância dos procedimentos Tipo-Adaptativo e Proto-Adaptativo), e com o ajuste obtido com o procedimento F-Organizativo.

Tabela 4.10 – Resumo dos ganhos com os processos de aprendizado.

Alcance (dias) :	$\frac{1}{2}$		1		1 $\frac{1}{2}$		2	
Procedimento ↓	$Er_{j/j-1}$ (%)	$Er_{j/j-2}$ (%)	$Er_{j/j-1}$ (%)	$Er_{j/j-2}$ (%)	$Er_{j/j-1}$ (%)	$Er_{j/j-2}$ (%)	$Er_{j/j-1}$ (%)	$Er_{j/j-2}$ (%)
Organizativo (j = 1)	-	-	-	-	-	-	-	-
Alternado (j = 2)	29,4	-	17,5	-	22,3	-	14,1	-
Peso-Adaptativo (j = 3)	16,8	41,2	18,3	32,6	13,5	32,7	9,53	22,3

O menor incremento de qualidade ocorre com alcance de 2 dias (para alcances maiores, espera-se atingir limites mais rapidamente). O fato de o modelo para alcance de $\frac{1}{2}$ dia ter tido um progresso que o torna viável, após os procedimentos Adaptativos, pode ser indício de que alguns modelos só revelam seu potencial após esgotadas todas as possibilidades para aprendizado.

É notável, também, a importância do procedimento Peso-Adaptativo, pois este proporciona melhorias consideráveis nos resultados dos modelos, quando já pareciam ter-se esgotado as possibilidades, por outros meios.

Os erros anteriores, especialmente com defasagem de 1 dia, podem ainda conter informações úteis para o processo de previsão, segundo os correlogramas resultantes, com limites de confiança de 95%, apresentados nas figuras 4.3, 4.4, 4.5 e 4.6. O uso de componentes do tipo média móvel, porém, exige recursividade ou uma forma iterativa de análise para o processo de aprendizado, o que constitui sofisticação adicional.

As correlações negativas entre os erros de previsão e os níveis concomitantes ou imediatamente anteriores refletem a tendência de ocorrerem erros positivos para níveis recessivos, e erros negativos para níveis ascendentes. Uma vez que o aumento do número de variáveis produz, nos processos de aprendizado, falso conhecimento devido às deficiências amostrais, o incremento dos modelos pode ser improdutivo, principalmente tendo-se em conta a desproporção entre o aumento da complexidade e as dependências observadas.

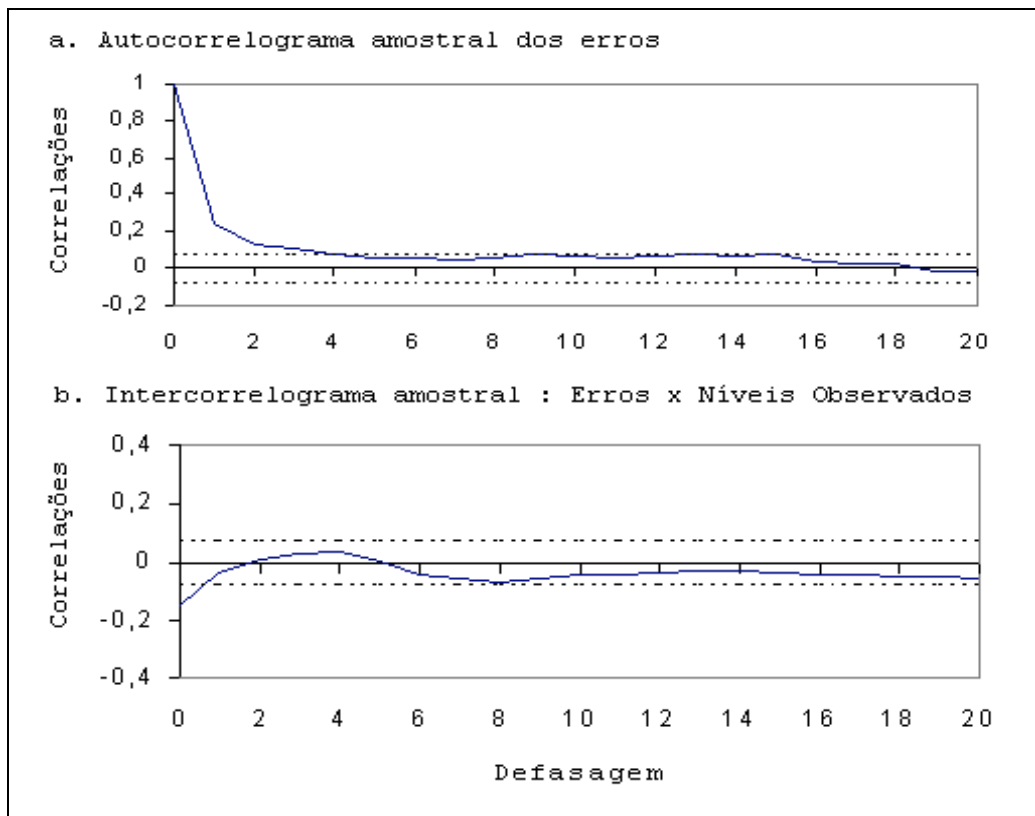


Figura 4.3 – Correlogramas dos erros do sistema especialista : Alcance 1/2 dia.




Figura 4.4 – Correlogramas dos erros do sistema especialista : Alcance 1 dia.




Figura 4.5 – Correlogramas dos erros do sistema especialista : Alcance 1 ½ dias.




Figura 4.6 – Correlogramas dos erros do sistema especialista : Alcance 2 dias.

4.4. As Previsões Categorizadas

A pesquisa da quantização que atende critérios estabelecidos de confiabilidade, com aumento da amplitude das categorias se for o caso, pode ser feita sem que isto implique em alteração das precisões das previsões pontuais, utilizando-se o mecanismo descrito na metodologia.

Enquanto que, utilizando-se este recurso para operação com menor número de categorias, os coeficientes de eficiência utilizados para avaliação das previsões pontuais permanecem inalterados, a modelagem direta, neste caso, conforme verificado no item 4.2, implica em redução desta eficiência.

No caso das previsões de níveis com os modelos pesquisados, tem-se, na tabela 4.11, os valores dos coeficientes de agrupamento, para cada alcance e para cada número de categorias possíveis, na versão atual do SELF. Os protótipos adotados para os níveis são os mesmos usados inicialmente, para nove categorias. Para sete, cinco, três e duas categorias, adotam-se os conjuntos (0, 150, 300, 400, 500, 650, 800), (0, 150, 300, 500, 800), (0, 500, 800) e (0, 800), respectivamente.

Tabela 4.11 – Coeficientes de agrupamento obtidos na verificação das previsões.

Nº Conjuntos →						
Alcance (dias)	Coefic. (%)	2	3	5	7	9
1/2	Fot	99,1	98,7	96,6	93,7	92,5
	Fop	100	100	100	100	100
	Foc	100	100	100	99,9	100
1	Fot	98,1	97,6	93,2	90	86,7
	Fop	100	100	99,9	99,0	98,5
	Foc	100	100	100	99,0	98,6
1 1/2	Fot	96,3	96,5	92,1	87,3	83,0
	Fop	100	100	99,9	97,8	97,3
	Foc	100	100	100	98,2	97,4
2	Fot	94,5	95,3	87,5	82,8	78,3
	Fop	100	100	99,7	96,1	95,6
	Foc	100	100	99,8	96,7	96,0

O critério empregado para a investigação da categorização mais desejável pode ser simples ou múltiplo, conforme dependa de um ou mais coeficientes de agrupamento. Claramente, a frequência de ocorrência total (Fot) é o coeficiente mais restritivo.

Um exemplo de critério simples é o de acerto total (ocorrência na categoria prevista com maior grau do que em qualquer outra). Pode-se obter, por exemplo, coeficientes de ocorrência total (Fot) de pelo menos 95%, para qualquer um dos alcances pesquisados, com uso de apenas três categorias (níveis ALTO, MÉDIO ou BAIXO). Neste caso, ainda podem-se contar com acertos de 100% na categoria secundária (Foc=100%), quando as observações ocorrerem fora da categoria principal. Ficam dúvidas, porém, quanto à utilidade, tendo-se em conta a amplitude dos intervalos.

Um critério múltiplo, representando um conjunto de condições que contemple também as categorias secundárias, pode ser formulado. Por exemplo, frequência de ocorrência total de 90% e de ocorrência combinada de 99%. Isso significa que aceita-se que 9% das observações podem ocorrer, com maior grau de pertinência que a qualquer outro conjunto, na categoria secundária, e não na categoria principal.

Outro critério simples, que pode, porém, ser utilizado, é considerar-se que serão, na verdade, emitidas previsões difusas, com duas categorias, com um indicativo de maior probabilidade para uma delas (a categoria principal). Neste caso, o coeficiente de ocorrência total combinada pode ser útil, para representar o critério adotado para a verificação.

Caso a quantização seja mais refinada, não há, necessariamente, perda de precisão em relação à previsão que propõe-se a acertar a ocorrência, na categoria principal, com maior grau de pertinência que a qualquer outra, porém com categorias mais amplas.

No presente estudo tem-se, para a quantização em nove conjuntos difusos, coeficientes de ocorrência total combinada favoráveis até mesmo para alcances de dois dias. Para as previsões com alcance de um dia, por exemplo, os coeficientes obtidos na simulação indicam previsões corretas nas categorias difusas (combinadas), com 98,6% de acerto, com ocorrência de 86,7% na categoria principal prevista.

É importante, neste ponto, a ilustração do significado das previsões em categorias combinadas. Por exemplo (figura 4.7), as previsões, com alcance de um dia, de níveis AL e MA, com graus de pertinência, respectivamente, de 0,8 e 0,2. Significa que espera-se, para o dia seguinte, nível entre alto (AL : em torno de 600 cm), e muito alto (MA : em torno de 700 cm), com tendência maior para alto. Conforme as frequências observadas na simulação, tem-se probabilidades de ocorrência, no domínio de Foc, de cerca de 99%, e no domínio de Fot, de cerca de 87%.




Figura 4.7 – Previsões em categorias combinadas.

O estudo, no ponto até onde é conduzido, não aponta a influência, para efeito dos acertos das previsões por categorias, dos graus de pertinência obtidos, a não ser para identificação dos conjuntos principal e secundário, pelas suas magnitudes relativas.

4.5. Os Modelos Empíricos Lineares

A análise da eficiência, com comparação entre os modelos construídos no SELF e os modelos empíricos lineares, é feita para a amostra completa (para todos os registros do período de verificação), e parcial (apenas para registros que representam ascensão).

O erro padrão (Ep), o erro máximo ocorrido (Ex) e o coeficiente de eficiência (Ce), são utilizados para a avaliação e comparação das previsões numéricas realizadas pelos modelos.

O cálculo das estatísticas de ascendência é bastante simples, uma vez que o erro padrão resulta de somatórios do quadrado dos erros, enquanto que o erro máximo depende da procura simples pelo maior erro ocorrido durante a simulação. Então, são efetuadas estas operações sempre que o nível atual seja maior do que o anterior e menor do que o posterior, o que acontece em cerca de 20% das ocorrências, durante a verificação.

Os modelos empíricos lineares (MEL), ajustados para o alcance de ½ dia e para os demais alcances (τ) consistem, respectivamente, nas equações 4.1 e 4.2 :

$$\hat{u}_{t+1/2} = \alpha_1 u_t + \alpha_2 P_t + \alpha_3 P_{t-1}, \tag{4.1}$$

$$\hat{u}_{t+\tau} = \alpha_1 u_t + \alpha_2 P_t + \alpha_3 P_{t-1} + \alpha_4 P_{t-2}, \tag{4.2}$$

onde \hat{u} e u representam, respectivamente, os níveis previstos e observados, e P_t , P_{t-1} e P_{t-2} , as precipitações, respectivamente, no tempo atual (t), e nos dias sucessivamente anteriores.

Foram utilizadas, para cada modelo empírico, as mesmas informações do modelo correspondente obtido com o SELF, para comparação da qualidade dos resultados em igualdade de condições. Na tabela 4.12, são apresentados os parâmetros ($\alpha_i, i = 1, 4$) obtidos para os modelos empíricos lineares, ao final do ajuste, para os quatro alcances considerados.

Tabela 4.12 – Parâmetros ajustados para os modelos empíricos lineares.

Alcance (dias)	α_1	α_2	α_3	α_4
½	0,971	0,801	0,699	-
1	0,927	2,377	0,955	0,306
1 ½	0,902	3,309	0,977	0,399
2	0,876	4,132	0,947	0,453

A comparação dos correlogramas dos erros resultantes dos modelos empíricos (figuras 4.8, 4.9, 4.10 e 4.11), com os correlogramas resultantes dos sistemas especialistas, indica diferença de comportamento destes erros.




Figura 4.8 – Correlogramas dos erros do modelo empírico : Alcance ½ dia.




Figura 4.9 – Correlogramas dos erros do modelo empírico : Alcance 1 dia.




Figura 4.10 - Correlogramas dos erros do modelo empírico : Alcance 1 ½ dias.




Figura 4.11 – Correlogramas dos erros do modelo empírico : Alcance 2 dias.

A dependência dos erros imediatamente anteriores, neste caso, cresce com o alcance, podendo ser reduzida com uso de componentes de média móvel. A dependência, ainda que reduzida, dos erros em relação aos níveis observados, é aparente, sendo, para níveis concomitantes, explicada pelas tendências das previsões de subestimarem níveis ascendentes e superestimarem níveis recessivos.

Uma vez que o objetivo destes modelos é servir de referência para comparações, em igualdade de informações utilizadas, dos modelos correspondentes construídos com a técnica dos sistemas especialistas com lógica difusa, o possível incremento destes modelos não é recomendável, para efeito desta pesquisa.

As previsões obtidas com os modelos são analisadas, tanto visualmente quanto estatisticamente, através dos coeficientes de eficiência e dos coeficientes de agrupamento, comparando-se, para os diversos alcances, o desempenho dos modelos.

Nas figuras 4.12, 4.13, 4.14 e 4.15, apresentam-se as séries de verificação com os níveis observados e previstos pela modelagem com o SELF, bem como os erros produzidos por estes modelos, e também pelos modelos empíricos lineares correspondentes, respectivamente para os alcances de $\frac{1}{2}$, 1, $1\frac{1}{2}$ e 2 dias.

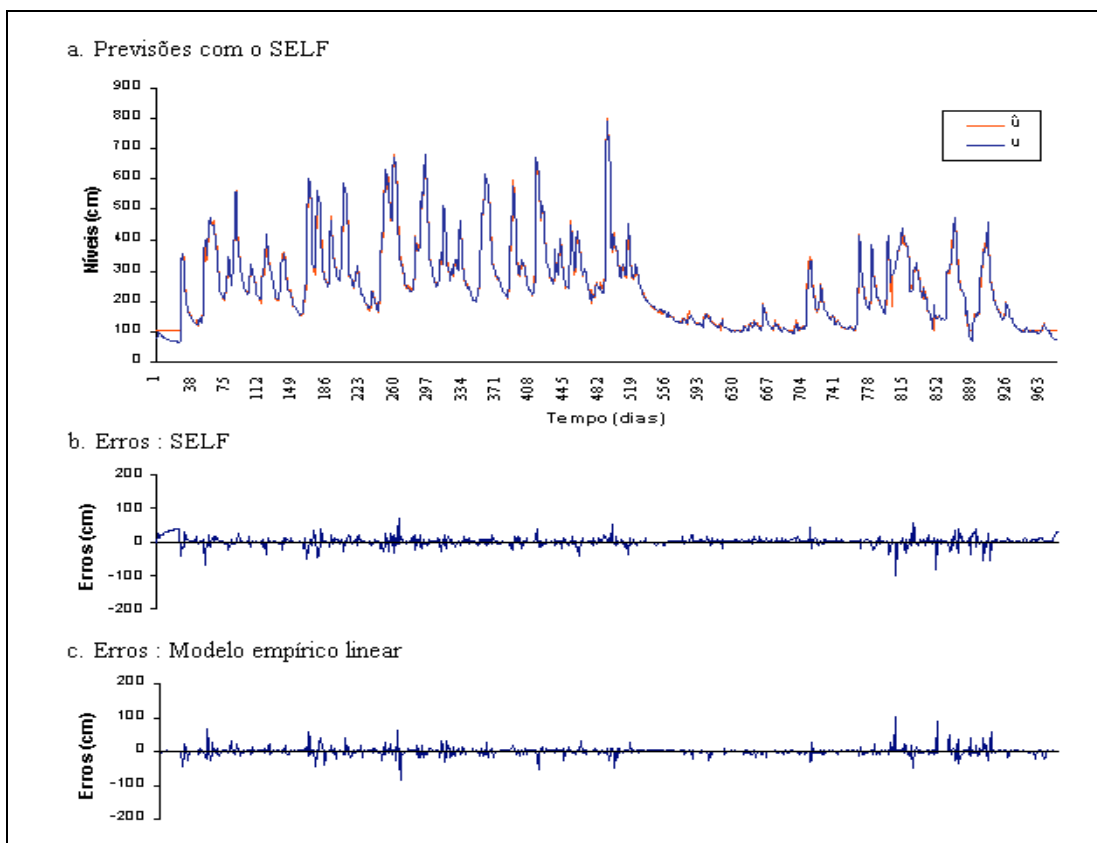


Figura 4.12 – Previsões : Alcance de 1/2 dia.




Figura 4.13 – Previsões : Alcance de 1 dia.




Figura 4.14 – Previsões : Alcance de 1 ½ dias.

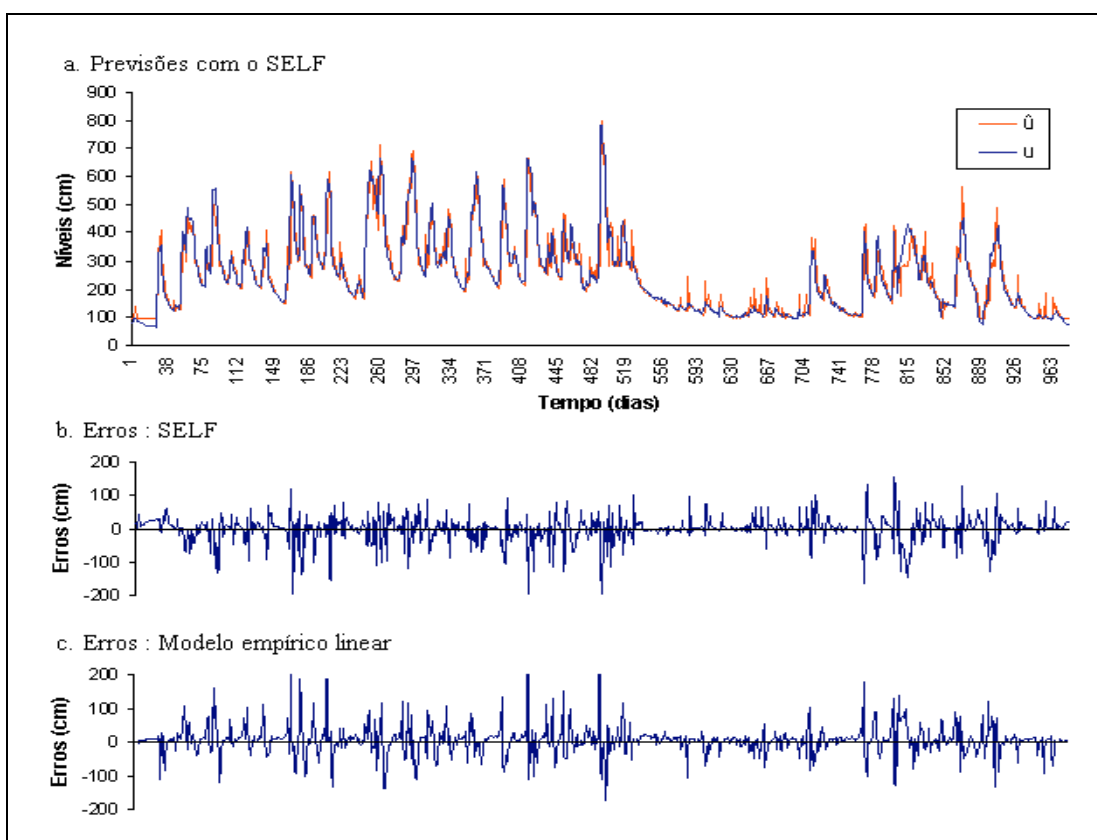


Figura 4.15 – Previsões : Alcance de 2 dias.

É notável o incremento da magnitude dos erros com o aumento do alcance, bem como sua redução durante os períodos contínuos de recessão. Também, observa-se que os erros dos modelos baseados no SELF não coincidem com os erros dos modelos empíricos lineares, sendo, em geral, um pouco menores.

Um procedimento mais seguro, porém, tendo-se em conta os aspectos subjetivos, é a utilização destas figuras para conferir as conclusões obtidas pelos coeficientes de eficiência e de agrupamento.

Na tabela 4.13, apresenta-se o desempenho comparativo dos modelos empíricos lineares (MEL) e dos modelos construídos com o SELF, através das estatísticas propostas, obtidas pela simulação de previsões para o período de verificação.

Tabela 4.13 – Desempenho comparativo dos modelos.

Alcance (dias) :		$\frac{1}{2}$		1		1 $\frac{1}{2}$		2	
Amostra	Parâmetros	MEL	SELF	MEL	SELF	MEL	SELF	MEL	SELF
Completa	Ep (cm)	11,5	13,1	25,0	23,6	30,9	29,2	46,0	40,3
	Ex (cm)	103	101	236	135	236	169	374	329
	Ce (%)	99,3	99,1	96,5	96,9	94,7	95,3	88,3	91,0
	Fot (%)	93,6	92,5	85,4	86,7	83,5	83,0	76,0	78,3
	Fop (%)	99,5	100	98,6	98,5	97,2	97,3	93,1	95,6
	Foc (%)	99,5	100	98,7	98,6	97,2	97,4	93,3	96,0
Parcial	Ep (cm)	16,6	18,6	41,4	35,6	51,7	44,4	77,4	65,7
	Ex (cm)	66,0	101	236	135	236	154	309	329

Os resultados dos modelos empíricos lineares são convertidos para previsões em categorias difusas, uma vez que este é um recurso proposto para uso geral, com qualquer tipo de modelo matemático.

Além disso, deseja-se comparar o desempenho dos modelos, tanto nos termos tradicionais (previsões pontuais, ou seja, numéricas), quanto nos termos adequados aos sistemas categorizados, em função dos coeficientes de agrupamento idealizados. Conforme o esperado, todos os indicadores deterioram-se progressivamente, à medida que aumenta o alcance da previsão.

Os modelos com base no SELF apresentam, em geral, desempenhos um pouco superiores aos dos modelos empíricos lineares, para previsões pontuais, conforme análise do erro padrão (Ep), erro máximo (Ex) e coeficiente de eficiência (Ce), com exceção do alcance

de ½ dia. Mesmo para este alcance, porém, observa-se pequena redução do erro máximo, quando utiliza-se o modelo correspondente do SELF. Redução esta que é notável, para os demais alcances.

As freqüências de ocorrência total (Fot), nas categorias principais, é, em geral, baixa, para as duas classes de modelos, enquanto que as freqüências de ocorrência parcial (Fop) e freqüências de ocorrência combinada (Foc) são, em geral, altas.

De acordo com o primeiro coeficiente (Fot), os alcances de ½ e 1 ½ dias são um pouco mais favorecidos pelos modelos empíricos lineares, enquanto que os demais são um pouco mais favorecidos pelos modelos gerados pelo SELF.

As freqüências de ocorrência parcial e de ocorrência combinada, por sua vez, apresentam valores muito semelhantes entre si. As previsões chegam a resultar em freqüências de ocorrência combinada de 100%, no caso do alcance de ½ dia.

As previsões combinadas em categorias difusas, são, para alcances menores, muito semelhantes, quando executadas com o modelo formado unicamente por bibliotecas de conhecimento, e pelo modelo empírico linear aplicado para obter-se previsões categorizadas. Para o alcance de dois dias, porém, os modelos empíricos lineares apresentam desempenho desvantajoso, em relação aos primeiros.

É notável como, para 2 dias de alcance, mesmo com as limitações observadas nas previsões numéricas, o modelo gerado pelo sistema especialista resulta em 96% de acerto nas categorias combinadas. O modelo empírico linear correspondente, por sua vez, acerta 93,3%, o que já constitui uma diferença, para menos, perceptível.

Para exemplificar, neste caso, os coeficientes de agrupamento estão dizendo que as previsões acertam 78,3% se forem formuladas para categorias simples (categoria principal, com maior grau de pertinência), e 96% dos casos, se forem formuladas difusamente, com duas categorias, principal (CP) e secundária (CS), do tipo : “entre categorias CP e CS, com tendência maior para CP”.

Se a previsão com dois dias de antecedência, com a precisão proporcionada pelas categorias adotadas, puder ser útil, terá sido viabilizada para este alcance unicamente graças às técnicas propostas para uso e interpretação das previsões categorizadas, tendo-se em conta os resultados até então obtidos para as previsões numéricas.

A análise dos erros padrões, nas situações de ascensão, revela que os modelos sob forma de sistemas especialistas difusos são melhores, para todos os alcances, com exceção do alcance de ½ dia. Porém, observa-se que, neste caso, o erro máximo cometido pelo modelo empírico linear não ocorre durante a ascensão, ao contrário do ocorrido com o modelo

baseado no SELF. Ora, a presença de um erro desta magnitude, possivelmente, altera estatísticas como o erro padrão, que é muito sensível a grandes diferenças, já que tem origem na soma de quadrados.

Um fato que chama a atenção é justamente que, embora a maior parte dos erros máximos ocorra na ascensão, conforme o esperado, existem exceções, como a previsão do modelo empírico linear para alcance de $\frac{1}{2}$ dia, ou do SELF, para alcance de $1 \frac{1}{2}$ dia. Além disso, estes erros máximos são muito grandes, e ocorrem, provavelmente, nos momentos mais críticos, quando as previsões confiáveis são mais necessárias.

A confiabilidade das previsões pontuais pode ficar sob suspeita, pois, ainda que com coeficientes de eficiência que atestam variâncias explicadas da ordem de 99% (alcance de $\frac{1}{2}$ dia), ou 95% (alcance de $1 \frac{1}{2}$ dias), os erros máximos são, respectivamente, de 101 e 169 cm.

4.6. A Redução da Rede de Aquisição

A principal alteração nas variáveis de entrada, como consequência da utilização de menor número de postos para sua determinação, é o aumento da amplitude, uma vez que maior número de postos resultam em ocorrências máximas menores.

Por exemplo, na série de verificação, os máximos totais diários médios das precipitações resultaram em 71, 89 e 92 mm para, respectivamente, médias obtidas de 11, 7 e 4 postos, e máximo de 124 mm para totais diários simples, do posto de Passo do Mendonça.

No caso de quatro postos, foram utilizados, além de Passo do Mendonça, os de Passo do Marinheiro, Dom Feliciano e Paraíso, buscando-se representar diferentes regiões da bacia (figura 4.1). Para a complementação do conjunto de sete postos, foram acrescidos a estes os de Passo da Capela, Serra dos Pedrosas e Passo São José.

Em um modelo baseado em equações, a adaptação deste para operação com as novas variáveis de entrada implicaria em modificações dos coeficientes de ajuste, enquanto que, no sistema especialista, as alterações devem ser feitas no espaço de domínio das variáveis que representam as precipitações.

As alterações necessárias, por sua vez, podem ser efetuadas por meio dos recursos desenvolvidos para o aprendizado Proto-Adaptativo. Este procedimento é utilizado, portanto, de modo a não interferir com as regras aprendidas, resultando em modificações sensíveis nos conjuntos difusos das variáveis que representam os totais diários precipitados.

Os protótipos dos conjuntos extremos variam, após a execução dos ajustes propostos, de 95, 65, 80 e 85 mm para os alcances de, respectivamente, $\frac{1}{2}$, 1, $1 \frac{1}{2}$ e 2 dias, para os valores apresentados na tabela 4.14.

Tabela 4.14 – Novas posições dos protótipos extremos.

Alcances (dias) :	½	1	1 ½	2
11 postos	95	65	89	85
07 postos	110	115	120	120
04 postos	110	130	115	115
01 posto	140	160	170	180

As modificações que ocorrem, entre um alcance e outro, ou das alternativas com 4 e 7 postos, entre si, podem ser atribuídas à aleatoriedade ou à imprecisão dos procedimentos, tendo-se em conta as pequenas diferenças observadas.

Porém há, sem dúvida, deslocamentos no sentido da expansão do domínio, tanto na passagem das condições originais (médias de 11 postos) para as reduzidas (médias de 4 e de 7 postos), quanto na passagem destas para a condição de uso de apenas um posto.

Na tabela 4.15, são apresentados os coeficientes de perda de eficiência, em relação ao uso das médias de totais pluviométricos diários de 11 postos, dos modelos que empregam médias correspondentes de sete e quatro, bem como dados de um único posto pluviométrico.

Tabela 4.15 – Perda de eficiência (%) : Conjuntos originais (O) e modificados (M).

Alcance (dias) :	½		1		1 ½		2	
	O	M	O	M	O	M	O	M
11 postos	-	-	-	-	-	-	-	-
07 postos	0,92	0	39,9	21,0	36,9	22,6	33,5	25,7
04 postos	6,21	5,11	46,1	34,7	54,3	35,8	46,9	39,8
01 posto	46,1	14,7	193,1	76,1	175,4	82,7	143,3	78,9

São examinadas duas condições de uso para cada alternativa, ou seja, a condição original (os protótipos dos conjuntos difusos são rigorosamente os mesmos que são usados com as médias de 11 postos), e modificada (os protótipos dos conjuntos que representam as categorias de chuvas são ajustados, pelo procedimento Proto-Adaptativo).

A visualização do significado de uma determinada perda de eficiência é proporcionada pela amostra representada na figura 4.16, onde apresentam-se os erros resultantes da

aplicação da modelagem com o SELF em função do número de estações de aquisição de dados pluviométricos.




Figura 4.16 – Previsões com alcance de 1 dia em função do número de postos.

São contempladas previsões com alcance de um dia, utilizando-se médias de totais diários precipitados de onze, sete e quatro estações, bem como leituras simples, de um único posto. Portanto, com perdas de eficiência em torno de 21%, 35% e 76%, respectivamente, para o segundo, terceiro e quarto caso, em relação ao primeiro.

Observa-se que as modificações dos conjuntos difusos das variáveis que representam as precipitações resultam em reduções significativas da perda de eficiência, em todos os casos, em relação ao uso dos conjuntos difusos originais. Porém, permanece uma perda de eficiência residual, a qual pode ser atribuída principalmente à redução da representatividade que ocorre com a diminuição do número de postos de aquisição de dados pluviométricos.

No caso do alcance de $\frac{1}{2}$ dia esta perda é menor, provavelmente porque a contribuição das precipitações para as previsões já é reduzida.

Nos demais casos, resta uma perda de eficiência entre 20% e 25% com o uso de sete postos, entre 35% e 40% com o uso de quatro postos, e em torno de 80% com uso de um único posto. Portanto, há uma redução da eficiência da previsão progressivamente maior com a diminuição do número de postos pluviométricos utilizados.

Na tabela 4.16, são apresentadas algumas estatísticas, para a comparação do desempenho dos modelos, para os diversos alcances, e com uso de diferentes configurações, em termos do número de postos pluviométricos.

Tabela 4.16 – Desempenho comparativo por número de postos pluviométricos.

Alcance (dias)	Nº de postos	Ep (cm)	Ce (%)	Fot (%)	Fop (%)	Foc (%)
½	7	13,1	99,1	92,6	99,9	100
	4	13,4	99,0	93,2	100	100
	1	14,0	98,9	91,9	100	100
1	7	25,9	96,3	85,7	98,7	98,8
	4	27,3	95,9	84,9	98,3	98,4
	1	31,2	94,6	85,1	97,7	97,9
1 ½	7	32,3	94,2	82,6	97,2	97,2
	4	34,0	93,6	79,7	96,6	96,9
	1	39,4	91,4	80,5	95,8	96,0
2	7	45,2	88,7	75,5	94,6	95,2
	4	47,7	87,4	74,5	93,6	94,0
	1	53,9	83,9	74,5	92,1	92,6

No caso do alcance de ½ dia, a redução da qualidade das previsões não é significativa, nem para as previsões pontuais, nem para as previsões sob forma de categorias.

Comparando-se os coeficientes obtidos utilizando-se sete postos pluviométricos com os coeficientes apresentados na tabela 4.13, observa-se diferenças de desempenho, porém estas diferenças são menos importantes quando considera-se que as previsões são feitas por categorias difusas combinadas.

Por exemplo, as frequências de ocorrência combinada, para previsões com 1, 1 ½ e 2 dias de alcance variam, respectivamente, de 98,6%, 97,4% e 96% para 98,8%, 97,2% e 95,2%, quando passa-se da condição de uso de 11 para sete postos.

É interessante que previsões difusas podem ser realizadas com uso de sete postos pluviométricos, com cerca de 95% de acerto nas categorias, para até dois dias de alcance.

Caso seja necessário rigorosamente 98% de acerto nas categorias combinadas, o alcance máximo que pode ser obtido com os modelos pesquisados é de um dia. Porém, esta margem de acerto é possível, neste caso, mesmo com apenas quatro postos pluviométricos.

Finalmente, o emprego de apenas um posto pluviométrico prejudica bastante os resultados, em uma taxa que aumenta, aparentemente, com o alcance da previsão. É possível, porém, que mesmo previsões, sob forma de categorias difusas, nestas circunstâncias, possam ter utilidade, em situações práticas.

5. Conclusões e Recomendações

A pesquisa com sistema especialista baseado em lógica difusa foi conduzida, em princípio, tendo-se em conta a experiência existente com modelos empíricos lineares, com os quais existe forte analogia quanto ao uso. As diferenças entre as duas propostas, porém, resultaram na adoção de estatísticas específicas para a avaliação da qualidade dos resultados, os quais foram apresentados também na forma simbólica ou de categorias.

Os principais recursos matemáticos que foram concebidos para o sistema tiveram por objetivo o aprendizado, sendo baseados em uma concepção alternativa às FAM's para a manipulação de conhecimento, a qual foi nomeada “matriz cognitiva”.

O desenvolvimento e utilização dos recursos computacionais, consolidados em um aplicativo (SELF – Sistema Especialista com uso de Lógica Fuzzy), constituiu-se em uma oportunidade para o domínio das técnicas relacionadas à lógica difusa. O SELF agrega procedimentos os quais compõe uma plataforma experimental para futuras pesquisas, bem como para a aplicação.

Uma situação real foi utilizada para testes destes recursos. Durante estes testes, foram identificadas dificuldades específicas da técnica dos sistemas especialistas para a previsão ou simulação de fenômenos naturais. Estas dificuldades são típicas de aplicações práticas, uma vez que resultam do uso de amostragens limitadas, sendo, principalmente, devidas a dois fenômenos, denominados de “falta de conhecimento” e “falso conhecimento”.

A “falta de conhecimento” ocorre durante o uso para a consulta, simulação ou verificação do modelo, quando não existem, na biblioteca de conhecimentos, regras associativas correspondentes a uma ou mais circunstâncias.

O “falso conhecimento” corresponde a regras, geradas no processo de aprendizado amostral, que não representam os fenômenos ou processos pesquisados, uma vez que são resultantes de ocorrências específicas de origem aleatória ou fortuita.

As conclusões obtidas foram baseadas, tanto na visualização dos resultados sob forma gráfica, quanto na análise de estatísticas. As estatísticas utilizadas foram os coeficientes de eficiência tradicionais, para as previsões pontuais, e os coeficientes de agrupamento, os quais foram idealizados para a análise da qualidade das previsões categorizadas.

A coerência e complementaridade apresentada pelas abordagens e pelos grupos de coeficientes é perceptível.

Como a propagação de descargas é relativamente simples, em comparação com os processos de transformação de chuvas, estes foram considerados mais promissores para a realização dos testes com vistas à investigação da validade do uso da técnica.

Uma bacia hidrográfica de dimensões consideradas adequadas a este primeiro estudo foi escolhida. A bacia do rio Camaquã é grande o bastante para dispensar a necessidade de previsão de chuvas (evitando-se, por enquanto, complexidades adicionais), e suficientemente pequena para o aproveitamento da técnica nos horizontes mais usuais, com alcances de no máximo alguns dias, o que possibilita comparações com modelos tradicionais.

A divisão da área da bacia hidrográfica em setores (leste e oeste) de captação é importante para o entendimento e confirmação do funcionamento do sistema natural. Neste caso, porém, os testes realizados comprovaram ser mais proveitoso o uso, como variável explicativa, de uma única série temporal, calculada para ser representativa das chuvas.

Foi demonstrada a possibilidade de uso, para modelagem de previsão em tempo atual, de conjuntos de séries temporais as quais não apresentam, necessariamente, o mesmo espaçamento temporal, e algumas nem mesmo possuem intervalos sucessivos constantes.

Por exemplo, utilizaram-se chuvas diárias, com acumulação às 07:00 horas, e níveis fluviais com duas leituras diárias, às 07:00 e às 17:00 horas. Os alcances testados foram intervalos de tempo correspondentes às leituras futuras dos níveis, apresentando, portanto, a mesma não uniformidade.

As observações realizadas revelaram que, enquanto a ausência de componentes no modelo pode produzir resultados insuficientes, o excesso destas pode prejudicar, pela produção de “falso conhecimento”. O “falso conhecimento”, neste caso, também é produto de amostras insuficientes, estando relacionado, teoricamente, à insuficiência de regras ou “falta de conhecimento”.

Os antecedentes de uma variável que não afeta o processo podem estar presentes em um registro, conjuntamente com os antecedentes de variáveis que possuem forte relação de causalidade com o conseqüente. Assim, este antecedente é relacionado conjuntamente, na regra associativa, gerando “falso conhecimento”.

Caso a amostra seja suficientemente grande, este problema é resolvido, uma vez que pode ficar aparente que qualquer conjunto, para esta variável, gera regra associativa, com os mesmos conjuntos das demais, o que significa que esta não afeta o processo.

Com base nestas observações, foi proposta uma técnica de “pesquisa hierarquizada”, a qual descarta, sucessivamente, componentes que não contribuam satisfatoriamente, ou mesmo prejudicam, concentrando-se esforços nas variáveis que revelam-se mais produtivas.

Esta técnica revelou-se adequada para a procura de um modelo satisfatório, embora não seja possível afirmar que este seja o “melhor” modelo, uma vez que trabalha-se com conexões lógicas. Uma variável que não mostrou-se útil em determinada configuração, pode ser muito importante quando associada a outras, ausentes na primeira tentativa.

Além disso, a pesquisa hierarquizada foi utilizada com uso de parte dos recursos desenvolvidos para o sistema, com vistas apenas à identificação dos modelos. Uma vez que os modelos de chuvas com alcance de $\frac{1}{2}$ dia acabaram por mostrar-se aproveitáveis somente quando foram utilizados os demais recursos de aprendizado, é possível que seja mais proveitoso, apesar do dispêndio adicional de tempo, o esgotamento de todas as possibilidades oferecidas, a cada nova tentativa para identificação.

O problema da “falta de conhecimento” constitui, em situações práticas, que dependem de séries limitadas de observações para o aprendizado amostral, um fator que pode restringir consideravelmente as aplicações, impedindo o uso de modelos com maior número de componentes, uma vez que o aumento do número de combinações implica na necessidade de amostragens cada vez maiores, as quais podem tornar-se impraticáveis.

Esta dificuldade, porém, foi superada com êxito por um recurso idealizado ao longo destes estudos, o qual é chamado de “biblioteca combinada de conhecimentos”. Neste caso, a mesma biblioteca de conhecimentos pode conter regras associativas de modelos mais simples, que requerem menor número de combinações, e que são acionadas, sucessivamente, à medida que os conjuntos de regras correspondentes aos modelos mais complexos não são suficientemente completos para conterem a situação representada pela ocorrência consultada.

A técnica das bibliotecas combinadas de conhecimentos é análoga a dispor-se, em um sistema de previsão, de diversos modelos, com níveis diferentes de complexidade e, conseqüentemente, diferentes exigências em termos de dados de entrada, para prevenir-se possível indisponibilidade de informações durante situações críticas.

Com este recurso, utilizou-se como base uma alternativa bem simples (no caso, os modelos autoregressivos), para a qual obteve-se conhecimento correspondente a toda a matriz cognitiva. A disposição dos demais modelos é hierárquica, de modo que a consulta a este ocorre quando todos os demais tiverem falhado sucessivamente, evitando-se, portanto, a ocorrência de “falta de conhecimento”.

A amostragem utilizada para aprendizado representou a maior parte das situações mais freqüentes, o que foi comprovado pelo pequeno número de ocorrências de “falta de conhecimento”, quando os modelos mais complexos foram utilizados isoladamente. Quando ocorreram situações diferentes, ou seja, casos omissos nos modelos principais, estes foram

resolvidos pelo conjunto de regras mais simples disponíveis na biblioteca combinada de conhecimentos, embora com menos precisão e menor margem de acerto.

Em princípio, o grau de refinamento da quantização das variáveis não precisa ser muito grande para haver uma representação suficiente, desde que as funções de pertinência aos conjuntos difusos sejam adequadas. No entanto, alguns autores (Wang et Mendel, 1992) encontraram precisões cada vez maiores, com o progressivo aumento do número de conjuntos, para o domínio definido.

Este aspecto foi parcialmente investigado, ou seja, com as variáveis explicativas que representam as precipitações. Verificou-se que existe um número específico, de três conjuntos difusos, que fornece melhores resultados do que outras possibilidades com maior ou menor grau de quantização.

No caso dos níveis, não foi possível obter-se uma conclusão, uma vez que, com nove categorias os resultados foram melhores do que com menor quantização, e este é o limite permitido, com a capacidade atualmente disponibilizada. O limite a este número de conjuntos difusos foi devido a que, inicialmente, desejou-se trabalhar com um número de categorias que pudesse ser facilmente referido por expressões lingüísticas usuais.

O efeito do recurso de extração de conhecimento adicional a partir de conjuntos difusos secundários na produção de regras associativas foi perceptível, com um aumento de 23% no número de regras geradas. A contribuição para a melhoria das previsões, proporcionada por este acréscimo de regras, foi, porém, pequena, com tendência a crescer com o aumento do alcance.

O procedimento F-Organizativo não contribuiu significativamente, o que é indício de que, possivelmente, outro critério para os pesos possa ser adotado com maiores vantagens.

Os procedimentos Adaptativos, por sua vez, podem ser aplicados sem modificação das regras aprendidas com os recursos Organizativos. Todas as alternativas de aprendizado Adaptativo contribuíram positivamente, porém os progressos obtidos foram lentos.

A cada novo recurso experimentado (Aprendizado Tipo-Adaptativo, Proto-Adaptativo, Alternado, Peso-Adaptativo), as melhoras foram pouco aparentes, porém, seu uso sucessivo produziu muita diferença ao final, o que não recomenda a supressão de nenhum destes procedimentos em favor dos demais.

A apresentação de resultados dos modelos, tanto os gerados pelo sistema especialista quanto os empíricos lineares, sob forma categorizada, foi testada mediante o uso do artifício desenvolvido para a simulação e geração de estatísticas, pelo SELF. O mecanismo utilizado

não afetou os coeficientes de eficiência, e forneceu indicadores da qualidade das previsões categorizadas.

Os indicadores, idealizados para este fim, foram três, chamados de coeficientes de agrupamento, os quais são a frequência de ocorrências totais (Fot), a frequência de ocorrências parciais (Fop) e a frequência de ocorrências combinadas (Foc).

Possíveis critérios para a interpretação, bem como para a avaliação da qualidade das previsões categorizadas foram discutidos, tendo-se por base, para estes fins, o uso dos coeficientes de agrupamento.

Concluiu-se, com base nas frequências de ocorrência combinada observadas nas aplicações, que as previsões em categorias difusas, compostas de duas categorias adjacentes, com respectivos graus de pertinência, são possíveis, com frequências aceitáveis de acertos, até mesmo para alcance de 2 dias. Viabilizou-se, neste caso, este alcance, o qual não mostrou-se adequado para previsões pontuais ou numéricas.

A análise visual dos erros dos modelos de previsão revelou um crescimento destes com o aumento do alcance, e uma redução sensível durante períodos prolongados de recessão, indicando que as maiores dificuldades ocorrem em períodos de ascensão e proximidades do pico, bem como períodos com modificações bruscas de tendência.

Os erros dos modelos empíricos lineares são diferentes, conforme os gráficos examinados, dos erros dos sistemas especialistas, sendo estes de menor amplitude, com exceção do alcance de $\frac{1}{2}$ dia.

Um índice adicional utilizado, em conjunto com os coeficientes de desempenho tradicionais, é o erro máximo (Ex). Este apresenta, por exemplo, valores superiores a um metro, em casos com coeficientes de eficiência (Ce) muito bons, de cerca de 99%. Como, provavelmente, os erros máximos ocorrem quando as previsões são mais necessárias (durante a ascensão), ficam dúvidas quanto a aceitar-se o coeficiente de eficiência como índice de qualidade confiável para previsões. Previsões sob forma de categorias apresentam, nestes mesmos exemplos, acertos de 100%.

Os modelos gerados com o SELF apresentaram, quase sempre, estatísticas mais favoráveis que os modelos empíricos lineares, tanto na análise geral quanto na análise parcial (considerando-se apenas períodos de recessão). A qualidade das previsões sob forma categorizada resultaram equivalentes, nos dois tipos de modelos, com exceção do alcance de 2 dias, quando o sistema especialista revelou-se notavelmente melhor.

Foram identificadas as duas principais fontes de erros quando estes modelos são utilizados para previsão em situações reais, em sistemas com menor número de postos de

aquisição de dados pluviométricos. Estas são a mudança da amplitude do domínio das variáveis que representam as precipitações, e a diferença na capacidade de representação das precipitações totais diárias médias sobre a bacia.

A análise da perda de eficiência, à medida que é reduzido o número de postos pluviométricos utilizados, foi realizada com uso de um coeficiente concebido para este fim, chamado de coeficiente de perda de eficiência.

O uso do procedimento Proto-Adaptativo resultou em maiores amplitudes para o domínio das precipitações, produzindo diferenças consideráveis nos protótipos extremos, para todas as alternativas testadas, de 11, 7, 4 e 1 posto. Também observou-se redução na perda de eficiência, após a aplicação deste procedimento, para todos os alcances considerados.

A redução do número de postos de aquisição de totais diários de chuvas não invalidou as previsões sob forma de categorias, tendo sido obtidas frequências de ocorrência combinada de 96%, mesmo nos piores casos, até alcances de 1 ½ dias. Para alcances de 2 dias, porém, 95% de acertos ainda puderam ser obtidos com uso de sete postos pluviométricos. Com menor número de postos a qualidade das previsões, para este alcance, deteriorou-se rapidamente.

Tendo-se em conta os objetivos pretendidos com os estudos realizados, esta introdução ao uso de sistemas especialistas com uso de lógica difusa para previsão de níveis fluviais a partir das precipitações na bacia produziu resultados proveitosos, mesmo em comparação com técnicas já consagradas.

Observou-se que situações que ocorrem na prática proporcionam melhor conhecimento das limitações da técnica, bem como oportunidades para a superação destas deficiências.

Portanto, é recomendável o prosseguimento das pesquisas, com outras situações de previsão hidrológica em tempo atual, tendo-se em conta a especificidade de cada caso, e a necessidade de acumulação de experiências, para potencializar o uso e futuros desenvolvimentos.

Também é importante o prosseguimento dos estudos e desenvolvimentos técnicos, principalmente no que diz respeito a :

- Técnicas de aprendizado, com a produção de recursos com maior capacidade de aproveitamento de memória, para ampliação do número de variáveis explicativas e do tamanho das séries amostrais utilizadas, bem como do número de conjuntos difusos que pode ser empregado;

- Estudos dos aspectos probabilísticos das ocorrências para aprendizado, com vistas à redução da quantidade das regras que constituem-se em “falso conhecimento”;
- Aperfeiçoamento das bibliotecas combinadas de conhecimento, para operarem também como bibliotecas encadeadas, dispensando o trabalho de concatenação, atualmente necessário;
- Estudo de melhoramentos para incluir o operador **OU** (U), nas regras associativas utilizadas pelo sistema;
- Testes do desempenho das previsões com uso de dados das variáveis explicativas sob forma qualitativa. No caso das precipitações, pode ser interessante a verificação, para uma bacia menor, do efeito de previsões de chuva na forma de categorias, sobre os resultados;
- Experimentação de outras hipóteses possíveis para as diversas opções metodológicas empregadas, como a atribuição, a regra de composição, a desquantização, e o método utilizado para a escolha da categoria resultante;
- Programação dos futuros desenvolvimentos, bem como migração destes, para um ambiente mais atualizado, tendo-se em conta as limitações do ambiente DOS utilizado;
- Outros desenvolvimentos com lógica difusa para previsão hidrológica, como incorporação da técnica em modelos chuva-vazão tradicionais, baseados em reservatórios fictícios de armazenamento;
- E, finalmente, uso dos princípios da lógica difusa para outras aplicações, além de modelagem para previsão, como operação de reservatórios, alocação de recursos hídricos, estudos ambientais, etc.

Referências Bibliográficas

- ASKEW, A. J. 1997. Water in the international decade for natural disaster reduction. In: INTERNATIONAL CONFERENCE ON DESTRUCTIVE WATER-CAUSED NATURAL DESASTERS THEIR ABATEMENT AND CONTROL. 1997. Ananeim. **Proceedings**. Wallinford: IAHS. p. 3-11 (Publication n. 239)
- CORDERO, A.; LEON, A. T.; MEDEIROS, P. A. 1998. Real time flood forecasting with a stochastic model. In: INTERNATIONAL WORKSHOP ON NON-STRUCTURAL FLOOD CONTROL IN URBAN AREAS. 20-22 abril, 1998. São Paulo. **Proceedings**. São Paulo: ABRH. p. 135-145.
- CRUZ, Jussara C.; LANNA, A. E.; SILVEIRA, G. et al. 1987. Previsão de cheias em tempo real pelo uso conjugado de modelos semi-conceitual e empírico. In: SIMPÓSIO BRASILEIRO DE HIDROLOGIA E RECURSOS HÍDRICOS, 7, 1987. Salvador. **Anais...** São Paulo: ABRH. p. 499-510.
- DRAPER, Norman R.; SMITH, Harry. 1981. **Applied regression analysis**. 2nd, New York: John Willey. 709 p.
- DRIANKOV, D.; HELLENDORRN, H.; REINFRANK, M. c1996. **An introduction to fuzzy control**. 2nd, Berlim: Springer-Verlag. 316 p.
- FILL, H. D.; MINE, Miriam R. 1989. Um método para redução do intervalo de confiança em modelos de previsão de vazões. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 8.: Foz do Iguaçu. **Anais...** São Paulo: ABRH, v. 2, p. 41-52.
- JOHNSTON, P. R.; PILGRIM, D. H. 1976. Parameter optimization for watershed models. **Water Resources Research**. v. 12, n. 3, p. 477-486.
- KASABOV, Nicola K. 1996. **Foundations of neural networks, fuzzy systems and knowledge engineering**. Cambridge: Massachussets institute of technology. 550 p.
- KOSKO, Bart. 1992. **Neural networks and fuzzy systems: A dinamical systems approach to machine intelligence**. Englewood Cliffs: Prentice Hall. 449 p.

- LANNA, A. E.; INDURSKY, A. B. 1983. Predição de vazões médias mensais com modelos empíricos. **Revista Brasileira de Engenharia. Caderno de Recursos Hídricos**. Rio de Janeiro: ABRH. v. 1, n. 2, p. 59-91.
- LANNA, A. E.; VALENÇA, M. J. 1985. Previsão em tempo atual de cheias com a técnica recursiva dos mínimos quadrados: Aplicação à cidade de Blumenau-SC. In: SIMPÓSIO BRASILEIRO DE HIDROLOGIA E RECURSOS HÍDRICOS, 5.: 1985: Blumenau. **Anais...** São Paulo: ABRH. v. 3, p. 328-44.
- MANDANI, E. H. 1977. Application of fuzzy logic to approximate reasoning using linguistic synthesis. **IEEE Transactions on computers**. New York: IEEE. V. c-26, n. 12, 1182-1191.
- PEDROLLO, Márcia C. R. P. 1997. **Projeto análise de consistência de dados fluviométricos**: Bacias do Atlântico Sul, trecho sudeste, sub-bacia 87, sub-bacia do rio Camaquã. Porto Alegre : DNAEE. 54 p.
- PEDROLLO, Olavo C.; LANNA, Antonio E. 1991. Previsão de cheias em tempo atual em sistemas fluviais com contribuições laterais relevantes. **Revista Brasileira de Engenharia. Caderno de Recursos Hídricos**. Rio de Janeiro: ABRH. v. 9, n. 2, p. 25-51.
- PEDROLLO, Olavo C. 1999. Previsão Hidrológica de Curto Prazo com Chuvas Efetivas Determinadas pela Função Sigmóide. RBRH. **Revista Brasileira de Recursos Hídricos**. São Paulo: ABRH. v. 4, n. 2, p. 19-30.
- ROJAS, I.; POMARES, H.; ORTEGA, J. et al. 2000. Self-Organized fuzzy systems generation from training examples. **IEEE Transactions on fuzzy systems**. New York: IEEE neural networks council. v. 8, n. 1, p. 23-35.
- ROSS, Timothy J. 1995. **Fuzzy logic with engineering applications**. New York: McGraw-Hill. 600 p.
- SALAS, J. D.; DELLEUR, J. W.; YEVJEVICH, V. et al. 1980. Applied modeling of hydrologic time series. **Water Resources Publications**. 484 p.

- SUDKAMP, T.; HAMMELL II, R. J. 1994. Interpolation, completion and learning fuzzy rules. **IEEE Transactions on Systems, Man, and Cybernetics**. v. 24, n. 2, p. 332-342.
- TODINI, E. 1992. **From real-time flood forecasting to comprehensive flood risk management decision support systems**. Dordrecht: Kluwer Academic, 543 p. (Floods and flood management fluid mechanics and its applications, v. 15)
- TODINI, E.. 1998. The development of an operational decision support system for flood risk mapping, forecasting and management. In : INTERNATIONAL WORKSHOP ON NON-STRUCTURAL FLOOD CONTROL IN URBAN AREAS. **Proceedings**. São Paulo: ABRH. p. 23-41.
- TUCCI, Carlos E.; CLARKE, Robin T. 1980. Adaptive forecasting with a conceptual rainfall-runoff model. In: **Hydrological Forecasting: Proceedings**. p. 445-454.
- WANG, L.; MENDEL, J. 1992. Generating fuzzy rules by learning from examples. **IEEE Transactions on Systems, Man, and Cybernetics**. v. 22, n. 6, p. 1414-27.
- YOUNG, P. 1974. **Recursive approaches to time series analysis**. Bulletin. Essex: Institute of Mathematics and its Applications. v. 10, n. 415, p. 209-24.
- ZADEH, L. A. 1965. Fuzzy Sets. **Information and Control**. New York: Academic Press. v. 8, p. 338-353.
- ZADEH, L. A. 1973. Outline of a new approach to the analysis of complex systems and decision processes. **IEEE Transactions on Systems, Man and Cybernetics**. CMC-3. P. 28-44.
- ZIMMERMANN, H.-J. 1991. **Fuzzy Set Theory : And its applications**. 2nd, Boston: : Kluwer Academic Publishers, 399 p.