

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE CIÊNCIAS ECONÔMICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO

**APLICAÇÃO DE SISTEMAS ESPECIALISTAS NO PROCESSO DECISÓRIO:
UMA ABORDAGEM HÍBRIDA**

SÉRGIO IVAN VIADEMONTE DA ROSA

Prof.^a Dra. Beatriz de Faria Leão

Orientadora

Prof. Dr. Norberto Hoppen

Co-orientador

Porto Alegre
1994

Orientador:

Prof.^a Dra. Beatriz de Faria Leão

Pós-Doutora em Informática Médica

Erasmus Universiteit Rotterdam - Holanda, 1990

Co-orientador:

Prof. Dr. Norberto Hoppen.

Pós-Doutor em Sistemas de Informação

École des Hautes Études Commerciales - Canada, 1994.

Banca examinadora:

Prof. Dr. João Luiz Becker

Phd em Administração

University of Califórnia at Los Angeles - EUA, 1986

Prof. Dr. José Palazzo Moreira de Oliveira

Doutor em Informática.

Institut National Polytechnique de Grenoble - França, 1984.

Prof. Dr. José Mauro Volkmer de Castilho

Doutor em Informática.

Pontifícia Universidade Católica do Rio de Janeiro - Brasil, 1982.

Dissertação de Mestrado submetida ao Programa de Pós-Graduação em Administração/UFRGS como requisito parcial para a obtenção do título de Mestre em Administração de Sistemas de Informação.

"Modest pilot projects, with the name of Expert Systems, have demonstrated that a computer is capable of the same kinds of intelligent behaviour as a physician making a diagnosis, or a geologist deciding where to seek minerals... These Expert Systems do this in much the same way human experts do - by combining textbook knowledge with the rules-of-thumb that experience teaches and then making informed guesses about the situation at hand, whether sick human being or range and basin. We call such expertise in human intelligence, intuition, inspiration and professionalism. When a machine demonstrates the same kind of behavior, there is no compelling reason no to call it intelligence then, too."

"The Fifth Generation"

Edward Feigenbaum & Pamela Mccorduck.

*À minha mãe, pelo apoio, dedicação e
confiança.*

À minha irmã, pela companhia.

AGRADECIMENTOS

Ao colega e amigo Cláudio Gonçalo, pela confiança, ajuda e incentivo que tornaram possível a realização deste trabalho.

À Dra. Beatriz de Faria Leão pela orientação, competência e o dinamismo contagiante.

Ao Prof. Dr. Norberto Hoppen, pela orientação, incentivo, apoio e amizade desenvolvidos ao longo do curso de mestrado.

Ao Prof. Dr. João Luis Becker, pelo apoio no decorrer do curso de mestrado.

À CEEE, na pessoa do Eng. Darico Pedro Levi, chefe do Centro de Operação e Engenharia do Sistema, pela oportunidade à realização deste trabalho.

Ao Eng. Jairo Nehme dos Santos, chefe do Serviço de Operação do Sistema da CEEE, pela disponibilidade e paciência durante as entrevistas realizadas e na confecção dos inúmeros grafos de conhecimento, cuja participação muito contribuiu para conclusão desta dissertação de mestrado.

Ao Eng. Jaime Jeffman Filho, chefe da Seção de Programação de Operação da CEEE, pelas incansáveis e minuciosas explicações, as quais foram essenciais para o entendimento do problema estudado.

Ao colega Alex Guazelli, pelas explicações e testes referentes ao modelo de redes neurais MNC.

Aos colegas e funcionários do Instituto de Informática da UFRGS, pela ajuda e colaboração no desenvolvimento desta dissertação de mestrado.

A todas as pessoas que, direta ou indiretamente, auxiliaram no desenvolvimento desta dissertação de mestrado.

Aos estudantes, pesquisadores, cientistas e todas as pessoas que têm se dedicado e contribuído para o desenvolvimento desta fantástica área do conhecimento, que chamamos de Inteligência Artificial.

À CAPES, cujo apoio tornou possível a realização deste trabalho.

SUMÁRIO

AGRADECIMENTOS	4
SUMÁRIO.....	6
LISTA DE FIGURAS	9
LISTA DE TABELAS	11
LISTA DE ABREVIATURAS	12
RESUMO.....	13
ABSTRACT.....	15
1 INTRODUÇÃO	17
1.1 Objetivos	18
2 REFERENCIAL CONCEITUAL.....	19
2.1 Sistemas de Apoio à Decisão	19
2.2. Inteligência Artificial.....	20
2.3 Conjuntos Nebulosos	22
2.3.1 Imprecisão.....	22
2.3.1.1 Incerteza	23
2.3.1.2 Difusão	23
2.3.1.3 Ignorância.....	23
2.3.2 A Teoria dos Conjuntos Nebulosos	23
2.3.2.1 Conjunto Nebuloso.....	25
2.3.2.2 Aplicação da Lógica Nebulosa em Sistemas Especialistas.....	25
2.4 Sistemas Baseados em Conhecimento.....	27
2.5 Engenharia do Conhecimento.....	30
2.6 Sistemas Especialistas	32
2.6.1 Arquitetura de um Sistema Especialista	33
2.6.2 Tarefas aplicáveis a Sistemas Especialistas.....	34
2.6.3 Dificuldades nos Sistemas Especialistas.....	36
2.7 Sistemas Conexionistas.....	38
2.7.1 Dificuldades na Abordagem Conexionista	44

2.8 Sistemas de Arquitetura Híbrida.....	44
2.9 HYCONES: HYBRID CONNECTIONIST EXPERT SYSTEM.....	47
3 SISTEMA ESPECIALISTA PARA DETECÇÃO DE REGIME DE OPERAÇÃO - O CASO CEEE.....	50
3.1 O Sistema Hidroelétrico JACUÍ.....	50
3.1.1 Fatores condicionantes	52
3.1.2 Fatores determinantes.....	53
3.1.3 Operação dos Reservatórios	54
3.2 Adequação do problema à técnica de Sistemas Especialistas	56
4 METODOLOGIA	58
4.1 Engenharia de Conhecimento no problema CEEE.....	58
4.1.1 Construção dos Grafos de Conhecimento	60
4.1.2 As Variáveis Nebulosas	66
4.2 A Representação do Conhecimento	72
4.2.1 A integração entre as redes neurais e o paradigma simbólico	77
4.3 O motor de inferência.....	79
4.4 Aprendizagem	80
5 IMPLEMENTAÇÃO DO SISTEMA SECOX-HI.....	87
5.1 O ambiente computacional	87
5.2 Implementação da Base de Conhecimento	88
5.3 Operação do sistema SECOX-HI	92
5.3.1 Manutenção do conhecimento declarativo.....	93
5.3.2 Manutenção da base de casos.....	95
5.3.3 Módulo de consulta	96
6 BASE DE CASOS.....	98
7 BASE DE TESTES	101
8 VALIDAÇÃO	102
9 CONSIDERAÇÕES FINAIS	111
10 CONCLUSÕES.....	116
REFERÊNCIAS BIBLIOGRÁFICAS	117

ANEXO A	121
ANEXO B	123
ANEXO C	126
ANEXO D	128
ANEXO E	129
ANEXO F	130

LISTA DE FIGURAS

Figura 1 Grafo de Conhecimento.....	31
Figura 2 Arquitetura de um SE.....	33
Figura 3 Estrutura de um modelo conexionista.....	39
Figura 4 Topologia do Modelo Neural Combinatório.....	41
Figura 5 Modelo E-nebuloso e OU-nebuloso.....	43
Figura 6 Arquitetura básica do HYCONES	47
Figura 7 Esboço do sistema hidroelétrico JACUÍ.....	51
Figura 8 Bacia Hidrográfica Passo Real.....	54
Figura 9 Fluxo para diagnosticar os regimes de operação	59
Figura 10 Quadro descritivo da metodologia de construção dos grafos de conhecimento.....	60
Figura 11 Grafos de Conhecimento para regime de emergência.....	64
Figura 12 Grafos de Conhecimento para regime de vertimento.....	65
Figura 13 Grafos de Conhecimento para regime de alerta.....	66
Figura 14 Relação entre variação de vazão e seus atributos.....	67
Figura 15 Gráfico da função de pertinência para variação de vazão	69
Figura 16 Gráfico da função de pertinência para precipitações	70
Figura 17 Gráfico da função de pertinência para defluência turbinada.....	70
Figura 18 Gráfico de função de pertinência para defluência vertida	71
Figura 19 Gráfico da função de pertinência para afluência PBV para vertimento.....	71
Figura 20 Gráfico da função de pertinência para afluência PBV para alerta.....	72
Figura 21 Gráfico da função de pertinência para afluência PBV para emergência.....	72
Figura 22 As classes diagnósticos e evidências.....	74
Figura 23 Frame diagnóstico	75
Figura 24 Estruturas relacionais para associação diagnósticos/evidências.....	76
Figura 25 Relação das estruturas de evidências e atributos.....	77

Figura 26 Mapeamento de um Grafo de Conhecimento para as estruturas simbólica e conexionista.....	79
Figura 27 Fluxo de inferência do SECOX-HI	80
Figura 28 Manutenção de evidências.....	93
Figura 29 Manutenção de diagnósticos.....	94
Figura 30 Inclusão de ocorrências.....	96
Figura 31 Operação de consulta.....	97
Figura 32 Planilha para a montagem da base de casos.....	100
Figura 33 Frame para regime de vertimento.....	109
Figura 34 Redes Neurais com maiores sinais de saída.....	109
Figura 35 Grafos de Conhecimento colhidos dos especialistas para regime de vertimento.....	109

LISTA DE TABELAS

Tabela I Valores característicos do reservatório de Passo Real	51
Tabela II Desempenho das três versões do SECOX-HI	103
Tabela III Tabela de contingência comparativa das três versões do SECOX-HI	104
Tabela IV Valores X^2 obtidos na comparação entre as versões B1 e B2, B1 e B3	105

LISTA DE ABREVIATURAS

CEEE	Companhia Estadual de Energia Elétrica
COS	Centro de Operações do Sistema
DOS	Departamento de Operações do Sistema CEEE
GMC	Grafos Médio de Conhecimento
GPS	General Problem Solver
IA	Inteligência Artificial
MNC	Modelo Neural Combinatório
PBV	Passo Bela Vista
RPRE	Reservatório Passo Real
SAD	Sistema de Apoio à Decisão
SBC	Sistema Baseado em Conhecimento
SE	Sistema Especialista
SEC	Sistema Especialista Conexionista
SPO	Secção de Programação de Operação

RESUMO

O presente trabalho descreve a aplicação de um modelo híbrido para sistemas especialistas em um problema de tomada de decisão, do tipo classificatório.

O modelo híbrido para sistemas especialistas, denominado **SECOX-HI**, foi desenvolvido utilizando-se dois mecanismos de representação de conhecimento. O conhecimento é representado por um conjunto de estruturas de dados relacionais e por redes neurais. As estruturas de dados relacionais permitem uma representação flexível e compreensível do conhecimento do domínio, enquanto que as redes neurais possibilitam a automação da aquisição de conhecimento, a partir de uma base de casos, e a implementação do aprendizado indutivo. O modelo de redes neurais utilizado foi o *Modelo Neural Combinatório* (MNC), capaz de realizar o aprendizado heurístico através de reconhecimento de padrões observados.

A metodologia de construção de grafos de conhecimento foi utilizada para capturar o conhecimento dos especialistas sobre o domínio da aplicação. Adicionalmente, os conceitos da lógica nebulosa foram empregados para modelar as variáveis nebulosas do domínio da aplicação, bem como para definir a função de pertinência dos conjuntos nebulosos relacionados a essas variáveis. A metodologia de aquisição de conhecimento e a fase de engenharia de conhecimento são detalhadas no trabalho, assim como a determinação das variáveis nebulosas e os conjuntos nebulosos associados.

O modelo híbrido para sistemas especialistas, **SECOX-HI**, foi aplicado no problema de detecção de regime de operação do reservatório da usina hidroelétrica de Passo Real, no sistema hidroelétrico Jacuí, na companhia estadual de energia elétrica do Estado do Rio Grande do Sul (CEEE).

Para a validação do **SECOX-HI**, montaram-se três versões da base de conhecimento. A primeira versão, **B1**, contém os casos de ocorrências históricas levantados no centro de operações do sistema. A segunda versão, **B2**, foi montada a partir dos grafos de conhecimento colhidos dos especialistas. A terceira versão da base de conhecimento, **B3**, constituiu-se numa base híbrida, formada por porções das versões **B1** e **B2**.

Também, para efeito de validação do sistema, foi montada uma base de testes. A base de testes é composta por 30 ocorrências, aleatoriamente selecionadas. A versão **B1** do sistema concluiu corretamente 29 (96.7 %) dos 30 diagnósticos da base de testes. A versão **B2** do sistema concluiu corretamente 22 (73.4 %) dos 30 casos apresentados, e a versão híbrida do sistema, **B3**, concluiu corretamente 27 (90 %) dos 30 casos apresentados.

Pelos resultados obtidos na validação do modelo, pode-se verificar a eficiência do formalismo híbrido na representação do conhecimento; a eficiência e aplicabilidade de modelos de redes neurais para a implementação de métodos de aquisição automática de conhecimento, principalmente quando existe um banco de casos disponível para o treinamento da rede neural; a aplicabilidade da tecnologia de sistemas especialistas no suporte à decisão.

Como principais contribuições deste trabalho, pode-se destacar a aplicação da lógica nebulosa numa situação real, para a interpretação e modelagem de conceitos imprecisos; a utilização e validação de uma metodologia para aquisição de conhecimento, baseada em grafos; a especificação e aplicação de um modelo computacional que incorpora a explicitação automática de conhecimento, via registros de ocorrências históricas, e o aprendizado indutivo, pelo refinamento do conhecimento armazenado nas redes neurais.

ABSTRACT

This dissertation describes the application of a hybrid model for classification expert systems in a decision making environment.

The hybrid model for expert systems, named **SECOX-HI**, employs two knowledge representation mechanism. The knowledge is represented by a set of relational data structures and neural networks. The relational data structures provide flexible and comprehensible constructs for modeling the domain knowledge. The neural networks provide the means for automatic knowledge acquisition, by a case database, and enable the implementation of machine learning techniques.

The *Combinatorial Neural Model* (CNM) was the architecture chosen for the neural network environment. These model is characterized by its capacity of learning through the recognition of regularities observed in the outside world.

The methodology used for knowledge acquisition was the construction of knowledge graphs, extracted from the domain experts. In addition, the fuzzy logic concepts was used to model the fuzzy variables of the application domain, as well as to define the membership functions of the fuzzy sets related to these variables. The knowledge acquisition methodology, the knowledge engineering phase and the especification of the fuzzy variables are fully discussed.

The **SECOX-HI** system was applied at classification of operation states of the floodgates movements from a reservoir in a hydroeletic company named CEEE (Companhia Estadual de Energia Elétrica Rio Grande do Sul).

To validate **SECOX-HI** system, three versions of the knowledge base were consructed. The first version, **B1**, was automatically created based on the training of the case database. The case database is formed by records of historicals occurrences retrieved from the databases of the eletric company, CEEE. The second version, **B2**, is based upon the knowledge graphs extracted from experts in operation of floodgates. The third version, **B3**, is a hybrid version formed by parts of knowledge base version **B1** and **B2**. To validate these three versions of the knowledge base, 30

cases were randomly selected from the same database that originated the case database, excluding all cases that had already been previously selected.

Version **B1** gave 29 (96,7%) correct diagnoses out of 30; version **B2** gave 22 (73,4%) correct diagnoses and version **B3** gave 27 (90,0%) correct diagnoses. These results point to the efficiency of the hybrid formalism to the knowledge representation, the efficiency and applicability of neural networks models to implement the automatic knowledge acquisition methods, mainly when there is a case database available for training the neural model. The results also showed the applicability of expert systems in the role of a decision support tool.

The main contributions of this research are the application of fuzzy logic in a real world problem to interpret and model imprecise concepts; the using and validation of a knowledge acquisition methodology based on knowledge graphs; the design and application of a computational model that provides automatic knowledge acquisition by a case database and inductive learning through the refinement of the neural network knowledge.

1 INTRODUÇÃO

Sistemas que processam dados e fornecem informações constituem os sistemas típicos e convencionais de processamento de dados, voltados à automatização de tarefas rotineiras e procedurais. Um problema de tomada de decisão, via de regra, não é uma tarefa procedural, que pode ter sua solução expressa em uma seqüência bem determinada de procedimentos.

Sistemas especialistas são sistemas de computação voltados à automatização de tarefas não procedurais, que exigem o uso de heurísticas e conhecimento especializado na sua resolução. Por essa razão este trabalho se propôs a aplicar e validar um sistema especialista no suporte a um problema decisório.

Considerando-se que em alguns problemas de tomada de decisão existem registros de situações passadas, as quais podem ser usadas na resolução do problema, optou-se pelo uso de um sistema especialista capaz de utilizar uma base de casos no seu processo de inferência. Redes neurais possibilitam a automação da aquisição de conhecimento, a partir de uma base de casos, e a implementação de técnicas de aprendizagem, por constituírem-se de uma técnica com características fortemente adaptativas. Em vista disso, optou-se pela utilização de um sistema especialista híbrido, composto em parte pela abordagem simbólica e em parte pela abordagem conexionista.

Foi selecionado o problema de detecção de regime de operação dos reservatórios das usinas hidrelétricas do sistema Jacuí, na CEEE, para a aplicação do modelo híbrido de sistema especialista desenvolvido neste trabalho. Este problema foi considerado porque apresenta características compatíveis com a aplicação de sistemas especialistas, como a falta de uma solução algorítmica procedural na sua resolução devido, principalmente, ao problema da explosão combinatória e a necessidade do uso de conhecimento heurístico e especializado para resolvê-lo. Considera-se ainda a existência de registros de casos históricos, disponíveis para uso pelo sistema.

O método utilizado neste trabalho foi o desenvolvimento de um sistema computacional, um protótipo para sistema especialista híbrido, e sua validação utilizando um caso real de uma organização.

Esta dissertação de mestrado está assim dividida: o capítulo 1 apresenta as justificativas para a realização deste trabalho, o método utilizado e os objetivos do trabalho, o capítulo 2 abrange o referencial conceitual, o capítulo 3 apresenta uma descrição do problema decisório considerado, o capítulo 4 descreve a metodologia utilizada, o capítulo 5 descreve o processo de implementação do sistema computacional, o capítulo 6 descreve a construção da base de casos do sistema, o capítulo 7 descreve a construção da base de testes do sistema, o capítulo 8 descreve o método utilizado para a validação do sistema, o capítulo 9 traça comentários a respeito do desenvolvimento do sistema, sobre as limitações e contribuições do trabalho desenvolvido e o capítulo 10 apresenta as conclusões deste trabalho.

1.1 Objetivos

O presente trabalho tem por objetivos:

1.1.1 Validar um modelo híbrido de SEs em um problema de tomada de decisão do tipo classificatório (diagnóstico) que, no seu processo de inferência, inclua consulta a uma base de casos do domínio da aplicação.

1.1.2 Validar a capacidade de aquisição automática de conhecimento do SE híbrido, a partir de uma base de casos, isto é, validar sua capacidade de aprendizagem.

1.1.3 Aplicar o modelo híbrido de SE no problema de detecção de regime de operação dos reservatórios do sistema hidroelétrico JACUÍ. O SE proposto objetiva auxiliar os operadores da CEEE na detecção do regime de operação dos reservatórios das usinas hidroelétricas do rio Jacuí, tendo como base o reservatório da usina de Passo Real.

2 REFERENCIAL CONCEITUAL

Neste capítulo são descritos os principais elementos conceituais envolvidos no desenvolvimento deste trabalho, tais como sistemas de apoio à decisão, inteligência artificial, sistemas especialistas, sistemas conexionistas, lógica nebulosa e aprendizado de máquina.

2.1 Sistemas de Apoio à Decisão

Sistemas de Apoio à Decisão (SAD) são sistemas capazes de fornecer informações sobre uma parte do mundo real, sobre a qual possuem conhecimento, que auxiliem o consultante na solução de algum problema decisório [BON81].

Nas tarefas de tomada de decisão, muitas vezes, o fornecimento puro e simples de informações e a análise de dados, podem não ser suficientes para o suporte eficiente a uma boa decisão. Em alguns casos, seria de maior utilidade que o sistema possuísse o conhecimento sobre o domínio de sua aplicação e que fosse capaz de desenvolver um raciocínio sobre este conhecimento, de forma a gerar suas próprias conclusões e fornecê-las aos usuários, bem como as respectivas justificativas.

A tomada de decisão envolve análise de informações, muitas vezes, imprecisas, inexatas ou incompletas, análise de um número, normalmente grande, de possibilidades e montagem de possíveis cenários relacionados aos caminhos selecionados. A tomada de decisão, freqüentemente, envolve o uso de heurísticas e não possui um algoritmo que expresse sua solução, ou no caso de existir, sua implementação conduz a um processamento muito demorado envolvendo incertezas e complexidades, o que o torna inviável.

Os Sistemas Especialistas (SEs) constituem-se numa ferramenta apropriada para esse tipo de situação, pois permitem a automatização de tarefas que apresentam as mesmas características daquelas encontradas em problemas de tomada de decisão, ou seja, aplicam-se a tarefas cuja resolução não apresenta uma solução procedural e que envolve o uso de heurísticas e conhecimento especializado. SEs são utilizados como ferramentas de suporte a decisões, em áreas específicas, que

exijam conhecimento especializado. Como por exemplo, os vários SEs desenvolvidos para atuarem no auxílio a diagnóstico médico e na seleção de tratamentos [HAY83].

Paralelamente ao conhecimento especializado, adquirido por estudos e ou experiência prática, muitas situações complexas de decisão podem ser resolvidas, ou podem ter sua solução mais facilmente encontrada, examinando-se situações similares passadas. Um histórico de casos, quando acessível, também constitui-se numa poderosa ferramenta de auxílio em algumas tarefas de tomada de decisão, pois através de exemplos ocorridos pode-se fazer analogias e comparações entre uma situação passada e uma situação atual, verificando-se soluções e adaptando-as ao novo problema.

2.2. Inteligência Artificial

Fazendo-se uma retrospectiva do uso dos computadores, desde seu surgimento, pode-se constatar que inicialmente sua utilização foi dirigida a tarefas bem estruturadas e formalizadas, como cálculos numéricos e manipulação de grandes volumes de dados. São tipos de tarefas, nas quais as máquinas apresentam um desempenho muito superior ao humano na resolução. Porém, quando se estendeu a área de atuação dos computadores a tarefas de natureza simbólica, que para os humanos são de resolução natural e, normalmente, fácil, como a compreensão de linguagens naturais e imagens, planejamento, dedução ou a solução de problemas que apresentam complexidade exponencial (que envolvem explosão combinatória), o desempenho dessas máquinas foi extremamente baixo, devido a grande complexidade para a compreensão destas tarefas e a formulação de uma solução computacional.

É nesse ponto que atua a Inteligência Artificial (IA), procura tornar uma máquina capaz de executar tarefas que, por sua natureza cognitiva, até então, somente os humanos eram capazes de executar. Seu objetivo principal é construir uma máquina inteligente e, por conseqüência, pesquisar a natureza da inteligência [SCH92].

Em função das dificuldades encontradas nas pesquisas sobre a inteligência e na operacionalização dos conceitos pesquisados, desenvolveram-se diversas linhas de pensamento em IA.

As principais linhas de pensamento que tem dirigido a IA são [COS86]:

"- A linha estruturalista, onde a inteligência de um sistema é referida ao seu comportamento e o comportamento inteligente é derivado das estruturas concretas e ou lógico/linguísticas. Como principais fontes de inspiração para esta linha têm-se os princípios neurofisiológicos e as estruturas lógicas não convencionais.

- A linha comportamentalista, que não considera a existência da inteligência intrínseca na estrutura da máquina. Seu principal objetivo é a simulação do comportamento humano, com inspiração na psicologia do processamento de informação.

- A linha funcionalista, onde a inteligência é atribuída as funções de adaptação da máquina ao meio externo. Esta linha de pensamento considera que a inteligência é tanto maior quanto maior for o grau de adaptação do sistema ao ambiente. Seu principal objetivo é aprimorar as formas intrínsecas de adaptação da máquina."

Segundo Rich [RIC83]: "IA é o estudo dos meios pelos quais os computadores podem ser utilizados para executar tarefas cognitivas, as quais atualmente ainda são melhor executadas por pessoas".

Para Simon [SIM81]: "IA é o uso de programas de computador e técnicas de programação para clarificar os princípios da inteligência em geral e do pensamento humano em particular".

Para Minsky [MIN68]: "IA é a ciência de fazer com que máquinas façam coisas que requereriam inteligência se fossem feitas pelos homens".

Esta diversidade de definições não se deve à ciência IA propriamente dita, mas sim ao aspecto da "inteligência" em si. Não se conhece precisamente o que é e nem como opera a inteligência.

Para melhor compreender-se o termo, ao invés de buscar uma definição precisa, é melhor considerar que atributos espera-se encontrar em uma entidade inteligente. Segundo Schank [SCH92], alguns desses atributos são: capacidade de comunicação, conhecimento interno (sobre seu próprio conhecimento), conhecimento externo (consciência do ambiente externo), objetivos e criatividade. Considera-se ainda a capacidade de aprendizagem, pois, segundo Schank, um programa que não é capaz de aprender não é um programa de IA.

Portanto, podemos entender IA como sendo a ciência que procura dotar as máquinas de tais atributos, ou que elas comportem-se de tal forma, a fim de resolver situações consideradas, até então, especificamente do domínio humano.

As áreas de atuação da IA, pelo modelo de Nilsson [NIL80] são:

- psicologia do processamento de informações;
- engenharia da linguagem;
- visão computacional;
- robótica;
- programação automática;
- demonstração automática de teoremas;
- engenharia do conhecimento;
- jogos de estratégia.

2.3 Conjuntos Nebulosos

2.3.1 Imprecisão

Um dos principais problemas que deve ser considerado na elaboração de sistemas especialistas é o tratamento da imprecisão. A imprecisão de dados, conceitos e raciocínio faz parte do raciocínio humano e, portanto, constitui aspecto relevante no projeto de sistemas especialistas.

A imprecisão pode ser caracterizada em três formas distintas: incerteza, difusão e ignorância [PAC91]. É importante esta classificação, pois a adequabilidade das diferentes técnicas de tratamento de imprecisão depende do tipo de imprecisão a que se direcionam [PAC91].

2.3.1.1 Incerteza

Este tipo de imprecisão ocorre quando a relação causa-efeito de uma condição formulada por um especialista não constitui um evento certo. A incerteza, normalmente, é tratada por uma abordagem numérica, baseada em probabilidades [PAC91].

2.3.1.2 Difusão

A difusão ocorre quando as informações são descritas qualitativamente. Nestes casos, a imprecisão está relacionada ao grau de pertinência de objetos à categorias de classificação. A principal abordagem dada para esse tipo de imprecisão é a teoria possibilística, fundamentada na teoria dos conjuntos nebulosos, ou difusos.

2.3.1.3 Ignorância

Considera-se ignorância, como sendo a ausência de avaliações da imprecisão, associada ao conhecimento no sistema ou em informações surgidas durante a inferência.

2.3.2 A Teoria dos Conjuntos Nebulosos

A lógica nebulosa, ou difusa, concentra-se na natureza da imprecisão presente no raciocínio e linguagem humanas.

A teoria da probabilidade fundamenta-se na lógica de duplo-valor e, por isso, não admite a ocorrência de determinado evento com um certo grau. Esta característica torna a teoria inadequada no tratamento da imprecisão por difusão, caracterizada pela ocorrência de predicados ou variáveis linguísticas, como por exemplo a *altura* pode ser classificada em *baixa*, *média* e *alta*, ou por quantificadores como *maioria*, *muitos*, *alguns*, etc [PAC91][ZAD86].

A teoria dos conjuntos nebulosos foi criada em 1965 por Lotfi A. Zadeh. Sua aplicação orienta-se a situações caracterizadas pela ineficiência da adoção de simplificações à realidade [PAC91]. A aproximação dos modelos à realidade apresenta algumas características importantes: a linguagem do modelo deve aproximar-se ao máximo da linguagem do domínio [ZIM85], a modelagem pressupõe a manipulação da imprecisão, não apenas no sentido da insuficiência de informação, como também no caráter vago no significado da mesma.

Segundo Zadeh [ZAD65]:

"A noção de um conjunto difuso oferece um conveniente ponto de partida para a construção de uma estrutura que é paralela em muitas relações à estrutura usada no caso dos conjuntos ordinários, mas é mais geral que esta e, potencialmente, pode-se provar ter um escopo muito mais amplo de aplicabilidade, particularmente nos campos de classificação de padrões e processamento de informações. Essencialmente, tal ferramenta oferece um modo natural de tratar problemas nos quais a origem da imprecisão está na ausência de critérios rigidamente definidos de classe de pertinência, ao invés de estar na presença de variáveis randômicas."

A teoria dos conjuntos nebulosos procura tratar a imprecisão inerente a linguagem e raciocínio humano por elementos que não guardam a modelagem rígida da lógica de duplo-valor [PAC91]. O alvo principal da teoria refere-se à conceitualização de conjuntos cujos limites não são rigidamente definidos. O conceito de pertinência de um elemento X a um conjunto A é estendido da forma clássica (X pertence a A ou X não pertence a A) para uma forma nebulosa (X pertence a A com um grau de pertinência $\mu_A(X)$).

2.3.2.1 Conjunto Nebuloso

Pela definição de Zimmermann [ZIM85]:

Dado X uma coleção de objetos denotados genericamente por x , então um conjunto nebuloso \tilde{A} em X é um conjunto de pares ordenados:

$$\tilde{A} = \{ (x, \mu_{\tilde{A}}(x)) / x \in X \}$$

onde:

$\mu_{\tilde{A}}(x)$ é chamada função de pertinência de x em \tilde{A} . Esta função mapeia X para o espaço de pertinência M . A função de pertinência é definida sobre um subconjunto de números reais cujo supremo é finito. Elementos com um grau zero de pertinência geralmente não são considerados.

2.3.2.2 Aplicação da Lógica Nebulosa em Sistemas Especialistas

Zadeh aponta cinco aspectos para justificar a utilização da lógica nebulosa no tratamento de imprecisão em sistemas especialistas [PAC91][ZAD83]:

1 - Tratamento de Proposições

Na lógica clássica, uma proposição P pode assumir os valores falso ou verdadeiro. Em lógica de múltiplos valores, uma proposição pode ter um valor-verdade intermediário que pode ser um elemento de um conjunto finito P ou infinito de valor-verdade. Na lógica nebulosa, os valores-verdade podem variar sobre subconjuntos difusos de P .

2 - Tratamento de Predicados

Ao contrário do que ocorre na lógica de duplo-valor, onde os predicados devem ter tratamento clássico, na lógica nebulosa os predicados podem assumir a forma nebulosa, por exemplo: *grande, alto, cansado*, etc.

3 - Tratamento dos Quantificadores

No tratamento por lógica nebulosa, a generalidade é permitida na utilização de expressões como *maioria, muitos, alguns, poucos*, etc. Dessa forma, os quantificadores expressam de forma imprecisa a cardinalidade de conjuntos clássicos e nebulosos. Portanto, podem ser manipulados por lógica nebulosa pela caracterização dos mesmos como predicados nebulosos de segunda ordem.

4 - Tratamento dos Modificadores de Predicado

Muito usados em linguagem natural, os modificadores de predicado (*mais ou menos, extremamente, pouco*, etc) são passíveis de representação em lógica nebulosa. Devido a esse tratamento pode-se conceber sistemas que consideram variáveis lingüísticas, ou seja, variáveis cujos valores são palavras ou sentenças em linguagem natural.

5 - Qualificação de Proposições

Para se classificar uma proposição P em lógica de duplo-valor, utiliza-se os termos "falso" e "verdadeiro", operadores modais como "possível" ou "necessário" e operadores intencionais como "sabe-se", "acredita-se", etc. Em lógica nebulosa, há três modos de qualificação:

- Qualificação Verdade

P é t, na qual t é um valor-verdade nebuloso.

- Qualificação Probabilística

P é l , na qual l é uma probabilidade nebulosa.

- Qualificação possibilística

P é p , na qual p é uma possibilidade nebulosa, como por exemplo, "muito provável", "quase impossível", etc.

2.4 Sistemas Baseados em Conhecimento

O interesse principal das pesquisas em IA, na década de 60, concentrou-se na busca de métodos gerais para a resolução de problemas e para a prova automática de teoremas. Foram realizados avanços teóricos, como o General Problem Solver (GPS) de Newell e Simon. Os avanços práticos, contudo, foram pequenos. Quando os programas de propósito geral de resolução de problemas eram utilizados para resolver problemas específicos do mundo real, verificou-se uma série de complicações, que tornavam a sua utilização prática inviável. A tentativa de desenvolver sistemas de computação que implementem métodos efetivos e genéricos de solução de problemas esbarrou na complexidade do universo real.

Assim, os esforços de pesquisa foram dirigidos para a busca de métodos e conceitos gerais que tratassem de aspectos particulares do comportamento inteligente, e que pudessem ser utilizados como componentes de programas mais específicos [MAR91].

Foi no final da década de 70 que a comunidade de IA começou a perceber que a capacidade de um programa para resolver problemas em um determinado domínio provinha do conhecimento do programa sobre este domínio, e não apenas dos formalismos e métodos de inferência utilizados. A constatação fundamental foi que, para tornar um programa mais capaz, era preciso dotá-lo de conhecimento específico. Deste modo, a pesquisa deixou de lado a procura de métodos poderosos e gerais de resolução, e passou a preocupar-se com o conhecimento necessário para resolver um

determinado problema. A evolução destas idéias deu origem aos sistemas baseados em conhecimento (SBC).

SBCs são sistemas que utilizam técnicas de IA, com ênfase na representação do conhecimento. Utilizam este conhecimento para solucionar problemas que requerem inteligência humana [HAY83]. O conhecimento sobre um determinado domínio consiste das descrições, definições, relações e procedimentos que manipulam estes elementos do domínio [HAY83]. Extrair, organizar e tornar este conhecimento especializado utilizável computacionalmente é tarefa essencial na construção de SBCs.

Programas convencionais consistem, basicamente, de duas partes: dados e algoritmos. Algoritmos são os procedimentos para resolver uma tarefa específica e dados caracterizam os parâmetros desta tarefa. Esta é a diferença fundamental entre SBC e sistemas convencionais. O único conhecimento explícito em um programa convencional é a seqüência de ações a ser executada a fim de realizar uma tarefa. O conhecimento do domínio necessário para o desenvolvimento do sistema e execução da tarefa não está incluído no sistema, isto é, não está disponível ao próprio sistema [PAS93].

Em SBC, o conhecimento sobre o domínio deve ser representado explicitamente no sistema, ou seja, existe uma parte do sistema (a base de conhecimento) na qual o conhecimento está codificado de forma independente dos procedimentos que atuam sobre ele (mecanismo de inferência). Dessa forma, em um SBC, atualizações no conhecimento do domínio não implicam em alterações no código. Além disso, a presença de conhecimento explícito e acessível tem outras vantagens importantes [PAS93]:

- legibilidade: é fácil identificar o conhecimento a partir do qual o sistema foi construído;

- flexibilidade: se o conhecimento está explícito no sistema, e de forma acessível, ele pode ser utilizado para outras situações e por outros mecanismos de raciocínio. O conhecimento embutido em uma seqüência de comandos limita a utilização deste a uma única situação e a um único tipo de raciocínio;

- introspecção: o sistema pode ter conhecimento de seu próprio conhecimento, podendo dessa forma raciocinar sobre sua perícia e justificar suas respostas.

SBCs aplicam-se a tarefas distintas daquelas abrangidas pelos sistemas convencionais. Estas tarefas devem requerer uso de uma considerável quantidade de conhecimento especializado, utilizar representação simbólica, inferência simbólica e utilização de heurísticas no processo de resolução. São tarefas que, normalmente, não possuem um algoritmo para atingir a sua solução.

Para poder utilizar conhecimento em um computador é necessário adquirí-lo e representá-lo. O processo de aquisição de conhecimento consiste nas atividades combinadas de elicitación, interpretação e organização do conhecimento adquirido de alguma fonte e na sua posterior representação computacional. Esse processo é chamado de engenharia do conhecimento, reconhecido como uma das etapas fundamentais e mais difíceis no desenvolvimento de SBCs.

Representar conhecimento consiste em encontrar as estruturas adequadas para expressar o conhecimento do domínio da aplicação [NIL80]. Pode-se definir representação do conhecimento como a formalização e a estruturação do conhecimento em um computador, de forma que ele possa ser manipulado por um sistema gerenciador de bases de conhecimento [CAR89].

A tarefa de representar conhecimento é difícil, pois [PAS93]:

- 1) Os formalismos de representação de conhecimento da mente humana são desconhecidos;
- 2) A linguagem natural não pode ser utilizada diretamente como linguagem de programação;
- 3) Ainda não foi desenvolvido nenhum formalismo que seja adequado para representar todos os tipos de conhecimento;

4) Não existe um critério determinado para escolher um certo formalismo, dado um domínio de problema, ou para avaliar formalismos competitivos.

Existem vários formalismos utilizados para a representação do conhecimento. Lógica de predicados, regras de produção, redes semânticas, estruturas de frames são utilizados na abordagem simbólica e redes neurais na abordagem conexionista.

2.5 Engenharia do Conhecimento

O processo de engenharia de conhecimento compreende as tarefas de aquisição e representação de conhecimento por um sistema de computação.

O processo de aquisição de conhecimento é de difícil execução, portanto a utilização de uma metodologia de aquisição de conhecimento simples, aplicável a vários domínios e capaz de fornecer informações facilmente transferíveis para um formalismo de representação de conhecimento, vem a ser de grande utilidade na construção de SEs.

Uma das metodologias propostas para aquisição de conhecimento é a construção de Grafos Médio de Conhecimento (GMC), extraídos de múltiplos especialistas [LEA90]. Um GMC é definido como um grafo acíclico mínimo, que representa o conhecimento de especialistas para uma determinada hipótese de diagnóstico [MAC90].

O método para obtenção dos grafos inicia por uma fase de entrevistas com um especialista, onde é solicitado que sejam escolhidos fatores importantes na resolução do problema em questão. A seguir, os especialistas devem ordenar os itens selecionados de acordo com seu grau de importância para a resolução do problema e colocá-los na base do grafo. Os itens devem, então, ser ligados em nodos intermediários que representam a relevância de um conjunto de fatores para a resolução do problema, que sempre é representado pelo nodo mais ao topo do grafo. A última etapa na construção dos grafos consiste na atribuição de valores de

importância, numa escala de 0 a 10, para os itens da base e os agrupamentos de itens (nodos intermediários) [REA93].

A figura abaixo representa um grafo de conhecimento de um especialista para uma determinada hipótese H.

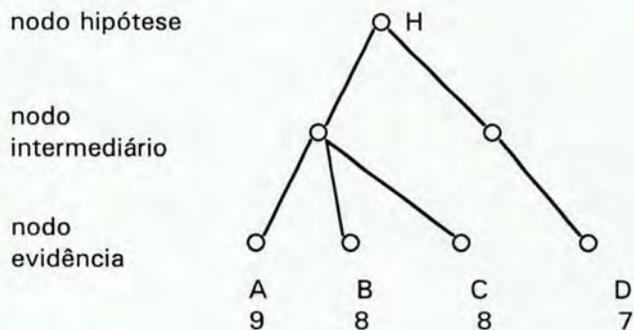


Figura 1 Grafo de Conhecimento

Três tipos de nodos podem ser identificados na figura 1:

- nodos de hipótese: é o nodo mais ao topo do grafo, representa a hipótese de diagnóstico nele considerado;

- nodos de evidência: são os nodos situados mais abaixo do grafo. Representam os sintomas, sinais, etc. São os dados que dão suporte à hipótese de diagnóstico. Estes nodos são organizados da esquerda para direita em ordem decrescente de importância;

- nodos intermediários: representam diferentes agregações de evidências usadas pelo especialista no seu raciocínio.

Os nodos intermediários geralmente representam um E-lógico entre as evidências. Já, o nodo de hipótese, representa um OU-lógico. Portanto, separando-se todos os sub-grafos conectados por um OU-lógico, um grafo de conhecimento pode ser facilmente transformado em outros [REA93]. Esta metodologia de aquisição de

conhecimento, GMC, é de particular relevância na construção de SE de função diagnóstico, ou classificatórios.

2.6 Sistemas Especialistas

Pela definição de Luconi [LUC86], "SE são programas de computador que usam raciocínio simbólico especializado para resolver problemas complexos. Usam conhecimento especializado sobre uma área de aplicação particular, por meio de raciocínio simbólico e trabalham em um nível de competência melhor do que os humanos não especialistas".

Um especialista humano é alguém que possui um conhecimento considerável sobre determinado domínio, adquirido através de estudo e prática. Produz boas soluções dentro de seu domínio, geralmente de forma rápida, além de ser capaz de explicar suas conclusões.

Um SE busca mimetizar o desempenho de um especialista humano na sua área de atuação, portanto, o conhecimento específico do domínio é de fundamental importância para SEs. Sua performance depende do uso dos fatos e das heurísticas usadas pelos especialistas. É projetado para atender a uma aplicação determinada e limitada do conhecimento humano. É capaz de emitir uma decisão, com apoio em conhecimento justificado, a partir de uma base de informações. É necessário que, além de inferir conclusões, seja capaz de aprender novos conhecimentos e, deste modo, melhorar seu desempenho de raciocínio e a qualidade de suas decisões.

SEs aplicam-se a tarefas de natureza simbólica, geralmente inviáveis de serem resolvidas pelos procedimentos algorítmicos da computação convencional, ou cuja resolução conduza a um processamento muito demorado, envolvendo complexidades e incertezas, normalmente só resolvíveis com regras de "bom senso" e com a utilização de um raciocínio similar ao humano. Os SEs possuem seu mecanismo de inferência apoiado em processos heurísticos, os quais podem não conduzir à solução do problema, mas na maioria das vezes levam a alguma solução de maneira mais rápida, justificada pelo próprio sistema.

2.6.1 Arquitetura de um Sistema Especialista

A arquitetura típica de um SE apresenta os seguintes componentes: .

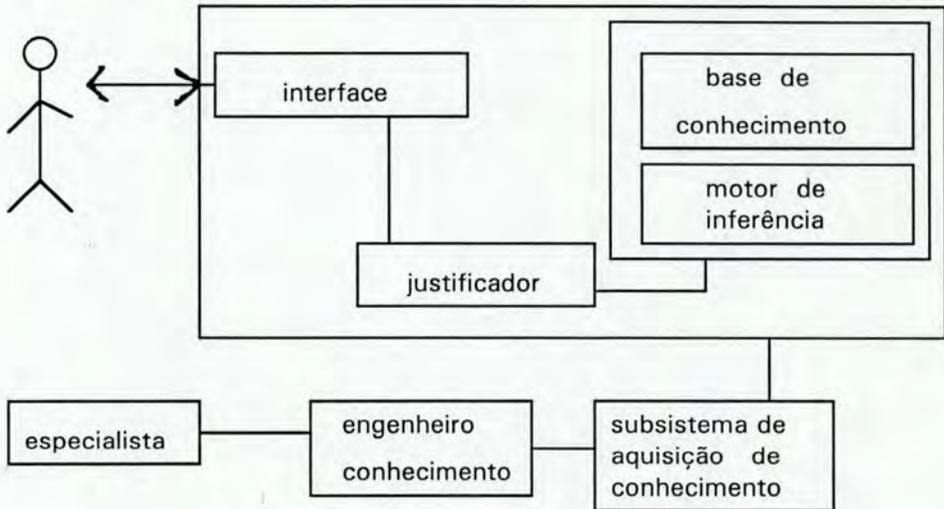


Figura 2 Arquitetura de um SE

- Interface: é o módulo responsável pela comunicação usuário e sistema, isto é, realiza a interação usuário/sistema. Na sua forma ideal deveria interagir com o usuário por meio de linguagem natural, permitindo a este, interagir com o sistema da mesma forma que seria feito com um especialista humano.

- Base de conhecimento: é o módulo onde está armazenado o conhecimento do sistema, de maneira adequada à utilização.

- Motor de inferência: módulo do sistema que avalia o conhecimento da base de conhecimento, e a partir daí vai direcionando o processo de resolução. Existem vários formalismos de inferência, isto é, estratégias para implementar o processo de inferência, pesquisa e conclusão. Como por exemplo, nos SEs baseados em regras, os principais formalismos de inferência são o raciocínio orientado pelas metas (*backward chaining*) e o raciocínio orientado pelas regras (*foward chaining*).

- Justificador: interage com o usuário esclarecendo como o sistema chegou a determinada conclusão, ou porque está tomando certa atitude (uma pergunta por exemplo), ou ainda, porque desconsiderou determinado fato. É um componente fundamental para o desempenho dos SEs. Nas tarefas onde aplicam-se SEs, o como o sistema chegou a determinada solução pode ser tão ou mais importante quanto a própria solução. Isso garante a confiabilidade do sistema.

- Subsistema de aquisição de conhecimento: a etapa de aquisição de conhecimento é de vital importância para um SE. Ela é realizada por um engenheiro de conhecimento, que procura extrair o conhecimento do especialista e inseri-lo na máquina. O ideal é que o próprio especialista interagisse diretamente com o sistema, atualizando o conhecimento da base. A automatização completa da aquisição de conhecimento não se verificou. O que existe é um conjunto de ferramentas para construção e depuração da base de conhecimento, como editores de textos, verificadores de regras e outros ambientes de desenvolvimento para processamento simbólico.

2.6.2 Tarefas aplicáveis a Sistemas Especialistas

Os SEs aplicam-se a tarefas de natureza simbólica. Trata-se de um contexto diferente dos sistemas de programação algorítmica convencional. Estas tarefas podem ser classificadas em *interpretação*, *predição*, *diagnóstico*, *monitorização*, *planejamento* e *projeto* [HAY83].

Interpretação consiste na análise de dados para determinar suas relações e seus significados. Deve-se considerar as possíveis interpretações, eliminando as inconsistentes.

Nas tarefas do tipo *predição*, partir de uma modelagem de dados do passado e do presente, determina-se um modelo para o futuro. Os SE previsores devem considerar situações e eventos que mudam com o tempo. A tarefa de predição requer integração de informações incompletas, deve considerar múltiplos futuros possíveis a partir da análise de dados de entrada, fazendo uso de raciocínio hipotético e verificando a tendência.

Diagnóstico é o processo de detectar falhas em um sistema a partir da interpretação de dados, geralmente imprecisos. Os problemas dessa tarefa são [PAS93]:

- 1- Falhas podem ser mascaradas por sintomas de outras falhas;
- 2- Falhas podem ser intermitentes. Às vezes, pode ser necessário forçar o sistema a fim de determinar as falhas;
- 3- O equipamento de diagnóstico pode falhar;
- 4- Dados sobre o sistema podem ser inacessíveis, de obtenção cara ou perigosa;
- 5- A combinação de modelos parciais, as vezes inconsistentes, em casos de sistemas não compreendidos completamente (por exemplo sistemas naturais como o corpo humano, em SE de diagnóstico médico).

Monitorização consiste na tarefa de interpretar sinais sobre o comportamento monitorado. Verifica-se, de maneira contínua, um certo comportamento, sinalizando quando uma intervenção for necessária. Um fator que implica numa intervenção é dependente de um contexto global em um instante de tempo, dessa forma a interpretação varia de acordo com os fatos que o sistema percebe a cada instante.

Planejamento consiste na elaboração de um programa de atividades a serem executadas, para atingir certo objetivo. Os SEs para planejamento operam em grandes problemas de solução complexa. Deve ser capaz de estabelecer etapas e sub-etapas, definir prioridades em casos de etapas e ou objetivos conflitantes, resolver problemas de interações entre etapas de diferentes sub-objetivos e coordenar a ação de múltiplos agentes.

Projeto é a tarefa de confeccionar especificações, tais que sejam atendidos objetivos para satisfazer requisitos particulares. Possui características parecidas com

a tarefa de planejamento. Como não é possível ter-se conhecimento de todas as conseqüências das decisões do projeto, o SE deve analisar possibilidades por tentativa, deve ser capaz de particionar o projeto em sub-projetos quando a complexidade for muito grande e resolver conflitos entre sub-projetos.

2.6.3 Dificuldades nos Sistemas Especialistas

O desenvolvimento de SEs, no decorrer da década de 70 em diante, trouxe resultados significativos para as pesquisas em IA, como também apontou algumas limitações na sua construção [ROL88]. Primeiramente verificou-se uma grande dificuldade na explicitação do conhecimento dos especialistas humanos e na formalização deste conhecimento para uma estrutura compreensível pelo computador.

Apesar dos esforços dispendidos e das ferramentas desenvolvidas, não existe uma técnica que possa ser qualificada como a melhor na explicitação do conhecimento de especialistas e posterior construção da base de conhecimento. As técnicas de aquisição de conhecimento normalmente usadas constituem-se de entrevistas estruturadas, não estruturadas e análise de informações. Ferramentas para a aquisição de conhecimento são essenciais na construção de grandes bases de conhecimento para sistemas especialistas. São vários os fatores que tornam a aquisição de conhecimento uma tarefa complexa, Eliseo destaca os seguintes [REA93]:

- o conhecimento para a construção da base de conhecimento de um sistema especialista não se encontra isolado, nem organizado de forma a permitir um mapeamento direto para um formalismo de representação de conhecimento;

- o conhecimento utilizado pelos especialistas para resolver problemas é geralmente composto de formulações heurísticas, sobre as quais nem mesmo os próprios especialistas têm consciência;

- o engenheiro de conhecimento, normalmente, não possui conhecimento do domínio da aplicação, o que dificulta o diálogo entre o especialista e o engenheiro de conhecimento;

- a explicitação de conhecimento compartilhado por um grupo de especialistas (conhecimento corporativo) torna-se mais complexa, pois além da dificuldade para a aquisição de conhecimento de um único especialista, surgem os problemas para cálculo do "conhecimento médio" do grupo de especialistas.

Um segundo problema encontrado no desenvolvimento dos SEs refere-se à aprendizagem. Especialistas humanos aprendem com a experiência, SEs não. A base de conhecimento é atualizada, normalmente, mediante a intervenção do engenheiro de conhecimento. Este é um problema crucial para SE e SBC em geral, pois estes não podem tratar o conhecimento da base de conhecimento de forma estática. O conhecimento é dinâmico por natureza, modifica-se através do tempo. Tarefas em que o conhecimento de seu domínio é estático, tendem a não serem pertinentes à aplicação da técnica de SEs.

Várias técnicas foram desenvolvidas para dotar os sistemas de computação de capacidade de aprender. Carbonell classifica as técnicas de aprendizagem em 4 classes [CAR89][REA93]:

- Aprendizagem por indução: é um método bottom-up. Consiste na formulação de conceitos com base na observação de ocorrências particulares de um fenômeno.

- Aprendizagem por dedução: é um método top-down, o raciocínio parte do geral para o específico. A partir da existência de um conjunto de fatos (exemplos) desenvolve-se o processo dedutivo, gerando-se novos modelos da realidade.

- Aprendizagem baseada no paradigma conexionista: consiste na utilização de redes neurais para armazenar o conhecimento e conduzir o aprendizado. Os sistemas conexionistas são treinados a reconhecer objetos de um conjunto de classes através da amostra repetitiva de conjuntos semelhantes de padrões.

- Aprendizagem baseada no paradigma genético: metodologia inspirada nas teorias de seleção natural. Através de algoritmos genéticos, buscam-se indivíduos

com maior capacidade de adaptação ao meio em uma população em constante mutação.

2.7 Sistemas Conexionistas

Os modelos conexionistas não constituem tecnologia nova. Na década de 50 surgiu um dos principais modelos, o PERCEPTRON, que despertou grande interesse devido a sua capacidade de aprendizado e adaptação. Porém sua utilização foi inibida devido a algumas limitações do modelo, bem como a limitações do hardware então disponível [MIN72]. Na década de 80 as pesquisas e trabalhos em redes neurais foram retomados, devido a alguns avanços nos modelos, como o procedimento para ajuste de pesos em redes inventado por Paul J. Werbs, o *backpropagation* [REA93].

Hoje existe grande interesse em cima dos modelos conexionistas, psicólogos se interessam por suas semelhanças estruturais em relação à mente humana, os pesquisadores de IA buscam nestes soluções eficientes para um dos grandes problemas da IA, o aprendizado de máquina [KNI89][REA93].

Os modelos de redes neurais visam desempenhar, não apenas funções inerentes ao cérebro, como também basear suas operações em conhecimentos da ciência sobre seu funcionamento e arquitetura. Acredita-se que parte da complexidade do cérebro humano resida na diversidade de células nervosas e nas inúmeras ligações entre elas [REA93].

A forma básica de funcionamento de um neurônio é relativamente simples. A complexidade das redes neurais compensa a relativa simplicidade de funcionamento de cada célula. Isto significa que a capacidade de uma rede neural de aprender, associar e reagir, enfim de executar as suas funções, não está associada a cada neurônio em particular, mas sim ao grande número de conexões entre eles [KAN92][REA93].

O processo de reconhecimento de padrões, existentes em todos os animais superiores, são notadamente paralelos e envolvem a análise simultânea de múltiplos aspectos. Significa que o sistema de percepção humano é capaz de explorar todas as

possíveis formas de classificação para um padrão, e só decidir por uma delas após a análise de todas as possibilidades [McC88].

Análoga ao reconhecimento de padrões visuais, é a capacidade de analisar múltiplas situações. Os modelos conexionistas buscam capturar esta capacidade do cérebro, relacionar elementos que influenciam-se uns aos outros.

Um modelo conexionista consiste de uma rede de células, relativamente autônomas, dotadas de capacidade de processamento. As células são ligadas por conexões, cada uma com um peso (P) associado, que corresponde à influência da célula no processamento do sinal de saída. Pesos positivos correspondem a fatores de reforço do sinal de entrada, e pesos negativos correspondem a fatores de inibição.

Os modelos normalmente apresentam um conjunto de células de entrada, por onde são passadas as informações para a rede. Um conjunto de células de saída, que apresentam os sinais de saída da rede e um conjunto de células intermediárias [REA93].

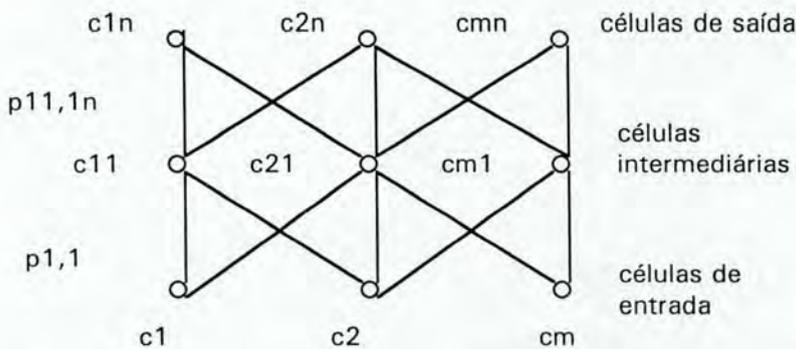


Figura 3 Estrutura de um modelo conexionista

Cada célula C_i é capaz de processar um sinal de entrada e transformá-lo em um sinal de saída. As células empregam uma função para o cálculo de ativação (saída). Este cálculo é efetuado com base nos sinais conduzidos pelas conexões que chegam até as células e seus pesos. Os valores de entrada e ativação das células podem ser discretos, nos conjuntos $\{0,1\}$ ou $\{0,1,-1\}$, ou contínuos nos intervalos $[0,1]$ ou $[-1,1]$.

O método estabelecido para o cálculo das ativações das células pode ser diferente para cada modelo conexionista. Em alguns modelos as células são percorridas em uma ordem fixa, em outros as células calculam suas ativações e apresentam suas saídas simultaneamente. Outros modelos selecionam uma célula aleatoriamente, processam sua ativação e alteram seu sinal antes de processar a ativação de outra célula.

Diversos modelos conexionistas foram desenvolvidos para utilização em vários tipos de tarefas, como no processamento de sinais, reconhecimento de padrões, processamento de imagens, processamento de conhecimento, etc.

Alguns desses modelos são [REA93]:

- (1) O PERCEPTRON (1957) utilizado para reconhecimento de caracteres impressos.
- (2) PERCEPTRON MULTICAMADAS (1974) usado no controle adaptativo de braços de robôs e processamento da fala.
- (3) Sistema ART (1978) usado no reconhecimento de sinais de radar e processamento de imagens.
- (4) REDES DE KOHONEN (1980) usado no reconhecimento de fala e aprendizado da distribuição de probabilidades de dados.
- (5) REDE DE HOPFIELD usado no reconhecimento de imagens.

Existem alguns modelos de redes neurais aplicados a SEs, como o SEC (1988) que provê métodos para a construção da rede neural por exemplos de treinamento, o RUBICON (1988) que possui uma estrutura híbrida que integra sistema baseados em regras ao modelo neural, o modelo neural combinatório (MNC). "O MNC é capaz de executar aprendizado heurístico baseado no reconhecimento de regularidades ambientais através de repetidas observações do mundo exterior" [MAC89].

O MNC foi utilizado no desenvolvimento da estrutura híbrida para sistemas especialistas, utilizada neste trabalho.

O MNC consiste de uma rede acíclica de três ou mais camadas. As camadas de entrada representam evidências, as camadas combinatórias agrupamento de evidências e a camada de saída as hipóteses [REA93].

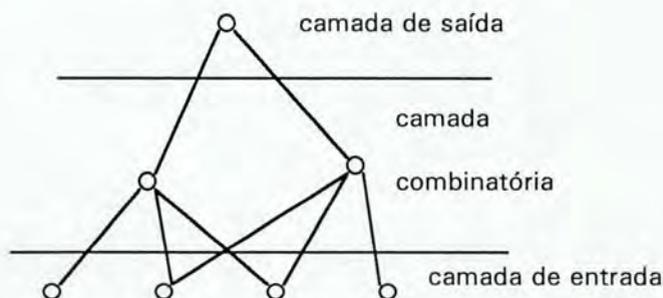


Figura 4 Topologia do Modelo Neural Combinatório

A camada de entrada é formada por células *fuzzy*, cada célula representa um achado específico. Recebem valores entre 0 e 1, indicando o grau de confiança que o usuário possui naquele determinado achado. Células em camadas diferentes são ligadas por conexões às quais se associam pesos, que representam a influência das células da camada inferior na saída das células da camada superior [MAC91].

As conexões da camada de entrada podem ser de dois tipos: inibitórias ou excitatórias. Uma conexão excitatória propaga o sinal de entrada utilizando o seu peso de conexão como um fator de atenuação. A conexão inibitória nega o sinal de entrada X , transformando-o em $(1-X)$, depois propaga o sinal através da multiplicação do sinal negado $(1-X)$ pelo peso da conexão.

A camada combinatória associa diferentes células de entrada (achados) em nodos intermediários, que representam os padrões (grupos de achados) que a rede aprende a reconhecer [REA93].

A camada de saída armazena as diferentes hipóteses de diagnóstico consideradas no domínio do problema.

O valor do sinal de saída de uma sinapse, ponto de conexão entre neurônios, é chamado de "Fluxo Evidencial" e calculado pela fórmula [MAC91] [REA93]:

$$FE = w \cdot E \cdot t \cdot w \cdot (1 - E) \cdot (1 - t)$$

onde:

E = sinal de entrada;

w = peso da sinapse;

t = tipo da sinapse, 1 para sinapses excitatórias e 0 para inibitórias.

Os neurônios processam os sinais de duas formas, o *E-nebuloso* e o *OU-nebuloso*:

- *E-nebuloso* : o neurônio seleciona o sinal de entrada mais fraco;

- *OU-nebuloso* : o neurônio seleciona o sinal de entrada mais forte.

O modelo MNC utiliza o *E-nebuloso* nas camadas combinatórias e o *OU-nebuloso* na camada de saída. A figura 5, demonstra as duas formas de processamento de sinais [MAC89]:

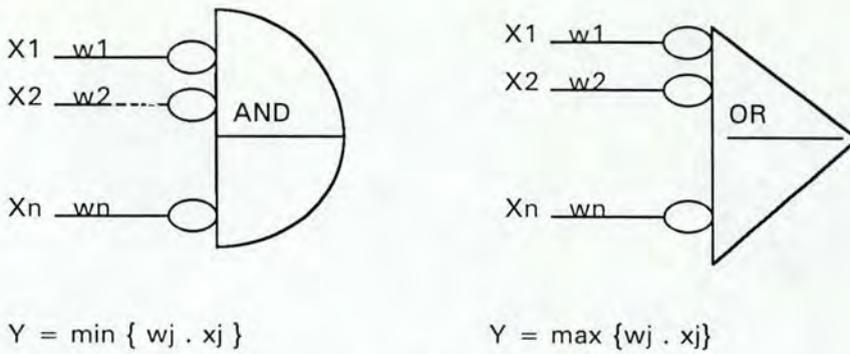


Figura 5 Modelo E-nebuloso e OU-nebuloso

onde:

- x_j representa os sinais de entrada das células,
- w_j representa o peso da conexão, indica a importância do sinal x_j para a saída Y ,
- Y representa o sinal de saída da célula.

A rede possui duas formas de operação: consulta e aprendizado.

No modo de consulta, a partir de um conjunto de evidências (nodos de entrada da rede), a rede propaga os sinais e obtém as hipóteses (nodos de saída da rede) que obtiverem um grau de aceitação maior que um parâmetro pré-estabelecido.

No modo de aprendizado, podem ser empregados dois métodos. Um dos métodos utiliza um algoritmo de punição e recompensa - versão arranque, para gerar uma rede operante a partir de casos de treinamento. O segundo método utiliza um algoritmo de punição e recompensa - versão de refinamento, para ajustar os valores dos pesos de conexão das redes a partir dos casos de treinamento [REA93].

Dessa forma o MNC possibilita a implementação do aprendizado heurístico em sistemas especialistas, além de permitir que o sistema especialista utilize uma base de casos no seu processo de inferência.

2.7.1 Dificuldades na Abordagem Conexionista

Os sistemas conexionistas possuem uma forte capacidade de aprendizagem automática, via exemplos de treinamento. Entretanto esta técnica envolve um grande número de exemplos e, portanto, uma considerável quantidade de tempo para treinar a rede neural [KNI89].

Além desse fator, o conhecimento adquirido pela rede neural normalmente é opaco, pois é armazenado na forma de pesos de conexões, tornando a tarefa de explanação do SE muito complexa [KNI89].

2.8 Sistemas de Arquitetura Híbrida

SEs de arquitetura híbrida são sistemas nos quais foram combinados os paradigmas simbólico e conexionista de representação de conhecimento. O paradigma simbólico utiliza frames, regras de produção e redes semânticas na representação do conhecimento, o paradigma conexionista utiliza as redes neurais.

Arquiteturas híbridas constituem-se numa forma de explorar as vantagens de ambos os paradigmas numa mesma estrutura. Sistemas conexionistas são eficientes para implementação de técnicas de aprendizagem, tanto indutiva como dedutiva, e para a aquisição automática de conhecimento.

O aprendizado indutivo é implementado por meio de algoritmos de treinamento das redes neurais por casos, o aprendizado dedutivo através da modificação na estrutura da rede, utilizando-se, por exemplo, algoritmos genéticos [REA93].

Algoritmos genéticos foram inventados por John Holland, inspirado nos conceitos da evolução biológica, para mimetizar alguns dos processos observados na evolução natural. Holland acreditava que, incorporados de forma apropriada em um algoritmo, esses processos poderiam resultar numa técnica para resolver problemas difíceis por meio de uma evolução, análoga ao que ocorre na natureza. São algoritmos

que manipulam cadeias de dígitos binários, os quais são chamados cromossomos. A única informação que eles fornecem é uma avaliação dos cromossomos produzidos, usando o resultado da avaliação para selecionar cromossomos de forma que os melhores reproduzam-se mais que os piores. Estes algoritmos usam codificações simples (de cromossomos) e mecanismos de reprodução [LAW91].

A aquisição de conhecimento pode ser totalmente automatizada por meio da criação de redes neurais e seu treinamento através de casos. Pode-se incorporar este tipo de treinamento nos sistemas híbridos, automatizando-se o processo de aquisição de conhecimento.

O conhecimento do domínio em uma rede neural é armazenado na forma de pesos de conexões, o que dificulta a compreensão deste conhecimento, tornando a tarefa de explanação muito complexa, ou seja, sistemas conexionistas aprendem, mas possuem dificuldade em explicitar esse aprendizado. As redes neurais não são um mecanismo de representação de conhecimento flexível, o que é essencial para SE.

Em SEs convencionais, baseados no paradigma simbólico, aprendizado e aquisição automática de conhecimento são de difícil implementação. Por outro lado, permitem o armazenamento de descrições completas do conhecimento do domínio e a implementação de processos de raciocínio lógico, utilizados na resolução de problemas. Por isso, a tarefa de fornecer explicações e justificativas sobre determinada ação ou conclusão são de fácil implementação. SEs convencionais representam o seu conhecimento de uma forma mais explícita e compreensível, embora possuam dificuldade no aprendizado.

SE de arquitetura híbrida constituem um método de aliar o potencial de ambos os paradigmas na representação e manipulação do conhecimento, constituindo-se numa estrutura capaz de aprender (paradigma conexionista) e que possui compreensão do que aprendeu (paradigma simbólico).

Apesar de ser uma técnica bastante recente, já foram desenvolvidos alguns SEs híbridos, por exemplo: aplicação em avaliação de projetos arquitetônicos, para tratamento de câncer de melanoma maligno, para diagnóstico de cardiopatias congênitas, para tratamento de efluentes cloacais e industriais (sistema WATTS)

[REA93]. Estes três últimos são SEs aplicados a problemas do tipo diagnóstico, o mesmo tipo de problema que foi tratado neste trabalho.

Os sistemas de arquitetura híbrida, em relação à interação entre sistemas especialistas e redes neurais, classificam-se [MED92][REA93]:

- **arquitecturas com componentes independentes:** estes modelos não apresentam nenhuma integração entre os módulos de redes neurais e a parte simbólica. Sua principal aplicação é na avaliação de desempenho entre ambas as abordagens numa aplicação específica.

- **modelos transformativos:** os modelos transformativos começam como um tipo de sistema e terminam como outro. Neste caso também não existe forma de integração entre os módulos simbólico e conexionista.

- **modelos fracamente acoplados:** nestes modelos existe uma integração entre a parte simbólica e a conexionista. A aplicação é decomposta entre ambas as partes, que se comunicam via arquivos de dados. Nesta abordagem, como existe a comunicação entre as partes do modelo híbrido, obtém-se os benefícios da integração, entretanto algumas desvantagens devem ser consideradas, como a redundância na representação em ambos os paradigmas, custo de comunicação entre os módulos, a manutenção da integridade do conhecimento é complexa.

- **modelos fortemente acoplados:** possui uma capacidade de interação e um desempenho melhores que o modelo anterior. A integração ocorre via estruturas de dados residentes em memória. Seu desenvolvimento e manutenção são muito difícil devido a complexidade da interface interna para comunicação.

- **modelos com integração total:** modelos de desenvolvimento bastante complexo, apresentam melhor desempenho que os demais e não possuem (ou possuem muito pouco) redundância na representação do conhecimento. Possibilita que os módulos simbólico e conexionista compartilhem estruturas de dados e representação do conhecimento, o raciocínio é conduzido de maneira cooperativa entre os módulos.

2.9 HYCONES: HYBRID CONNECTIONIST EXPERT SYSTEM

O HYCONES [REA93] é um protótipo de sistema especialista classificatório, que integra o formalismo de representação de conhecimento de *frames* ao modelo conexionista MNC. A figura 6 exemplifica a arquitetura básica do modelo.

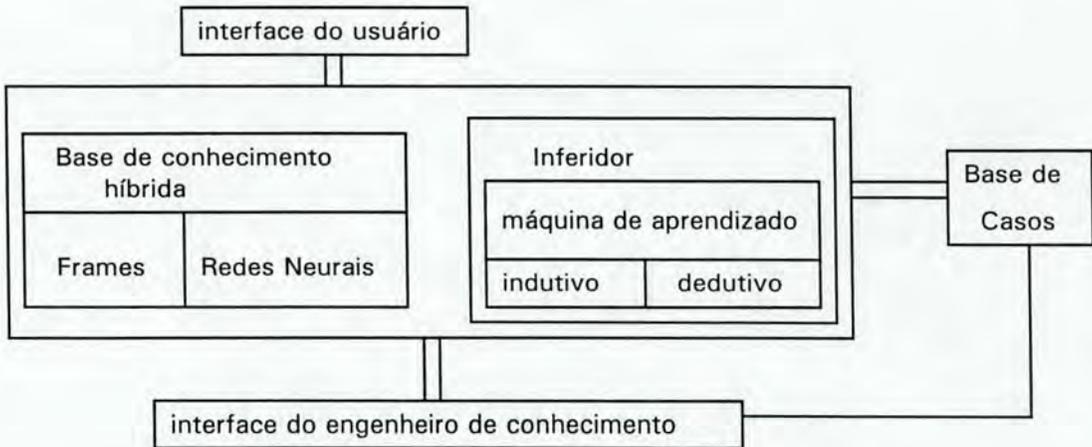


Figura 6 Arquitetura básica do HYCONES

Nesta arquitetura, a base de conhecimento híbrida utiliza o mecanismo de frames integrado as redes neurais para representar o conhecimento. O mecanismo de frames, usado na modelagem do conhecimento, opera em dois níveis: de *diagnósticos* e de *achados*.

Ao nível de achados descrevem-se os objetos elementares da aplicação que influenciam a detecção de diagnósticos. Ao nível de diagnósticos, descrevem-se os problemas de classificação que o sistema objetiva solucionar. Os frames de achados são descritos por um conjunto específico de atributos, definidos de acordo com o conhecimento do domínio. Estes atributos podem ser estabelecidos localmente ou herdados de frames hierarquicamente superiores.

Um frame de diagnóstico armazena referências a conjuntos de achados que influenciam em sua detecção. A ligação entre a hierarquia de frames de achados e

os frames de diagnósticos faz-se através de referências aos frames de achados existentes nos frames de diagnósticos.

Por meio da divisão dos frames em diagnósticos e achados, o formalismo de representação de conhecimento simbólico abrange todo o espectro da aplicação [REA93]. A hierarquia de achados descreve os aspectos declarativos do conhecimento do domínio, enquanto que os frames de diagnósticos mantêm as possíveis soluções para os problemas tratados.

O mesmo conhecimento descrito nos frames é representado nas redes neurais, do modelo conexionista MNC. A correspondência entre as estruturas do MNC e do mecanismo de frames é baseada no mapeamento dos grafos de conhecimento para as redes neurais. A tradução do grafo de conhecimento para a rede neural é direta. Cada caminho do grafo de conhecimento, que leva até a hipótese de diagnóstico, é representado por um caminho semelhante na rede neural. Os pesos correspondentes aos graus de importância de cada um dos nodos do grafo são diretamente mapeados para os pesos de conexão da rede neural.

O motor de inferência do **HYCONES** opera sobre as duas formas de representação de conhecimento. A inferência baseia-se no mecanismo de reconhecimento de padrões, implementado pelo modo de consulta do MNC. Um conjunto de evidências é apresentado às redes neurais, as quais, ativadas, passam a representar sinais de saída para cada um dos diagnósticos tratados pelo sistema [REA93]. Se algum caminho da rede apresentar sinal de saída maior que um parâmetro pré-estabelecido, o sistema apresenta o diagnóstico indicado pela rede neural como solução para o problema, caso contrário passa a trabalhar com o mecanismo simbólico de representação, a fim de restringir o campo de busca e guiar a subsequente coleta de informações.

A máquina de aprendizado tem o propósito de refinar o conhecimento armazenado na base de conhecimento, através da análise de conjuntos de exemplos contidos na base de casos. O **HYCONES** executa o aprendizado indutivo pelo ajuste de pesos das redes neurais usando o algoritmo de punição e recompensa do MNC, o aprendizado por dedução utiliza um mecanismo de reorganização e treinamento das redes neurais.

Pela implementação do aprendizado indutivo o **HYCONES** incorpora a capacidade de explicitação automática de conhecimento, por casos de treinamento, e o refinamento do conhecimento adquirido pelo aprendizado dedutivo, gerando novas combinações entre os nodos das redes neurais.

3 SISTEMA ESPECIALISTA PARA DETECÇÃO DE REGIME DE OPERAÇÃO - O CASO CEEE

O caso escolhido para o desenvolvimento e validação de um SE híbrido compreende a detecção dos regimes de operação dos reservatórios das usinas do sistema hidroelétrico JACUÍ da CEEE. Para melhor compreensão deste problema, descrevem-se, nesta seção, a configuração do sistema hidroelétrico, os fatores que influenciam o processo de tomada de decisão sobre a operação dos reservatórios, a operação dos reservatórios propriamente dita e a adequação do problema á técnica de SEs.

3.1 O Sistema Hidroelétrico JACUÍ

A Companhia Estadual de Energia Elétrica (CEEE) é a empresa responsável pela geração e distribuição de energia elétrica no Estado do Rio Grande do Sul.

Uma parte da energia elétrica consumida no estado é produzida pela própria CEEE e outra parte é comprada de outras empresas geradoras. Do total da energia consumida, 65% é adquirido do Sistema Interligado Brasileiro e de Itaipú, através do sistema de Transmissão da Eletrosul e 35% é gerado pela CEEE. Para a geração de energia elétrica a CEEE utiliza dois sistemas: as centrais térmicas (carvão e *fuel-oil*) e as centrais hidráulicas, distribuídas em três grupos: pequenas usinas, Sistema Salto (Canela) e Sistema Jacuí.

O sistema hidroelétrico JACUÍ é composto por três usinas hidroelétricas, com seus respectivos reservatórios, dispostas ao longo do rio Jacuí: Passo Real, Jacuí e Itaúba.

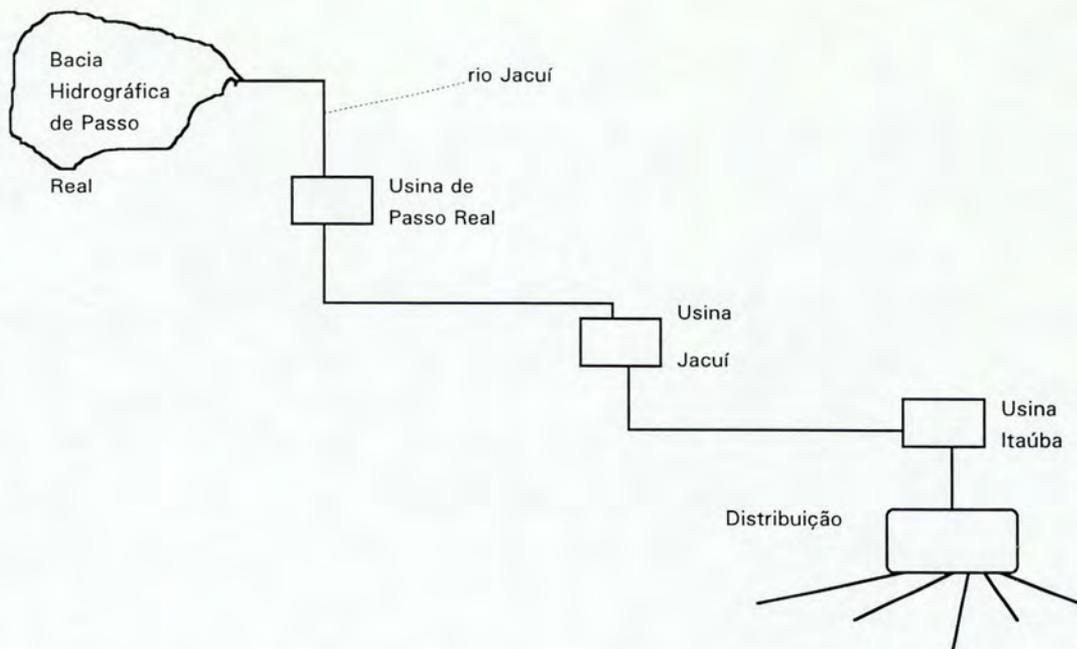


Figura 7 Esboço do sistema hidroelétrico JACUÍ

Os reservatórios possuem algumas características técnicas de construção, que delimitam a capacidade de operação da respectiva usina. A tabela abaixo relaciona estas características através do exemplo do reservatório da usina de Passo Real, o maior dos reservatórios do sistema Jacuí.

Tabela I Valores característicos do reservatório de Passo Real

NÍVEL MÁXIMO EXCEPCIONAL (m)	1.10
NÍVEL MÁXIMO OPERACIONAL (m)	0.00
NÍVEL TOPO DAS COMPORTAS (m)	0.50
NÍVEL MÍNIMO OPERACIONAL (m)	- 14.00
NÍVEL DA CRISTA DO VERTEDOURO (m)	- 11.00
VOLUME BRUTO (hm ³)	3645.5
VOLUME ÚTIL (hm ³)	2356.1
VOLUME MORTO (hm ³)	1289.4
ÁREA INUNDADA (km ²)	225.5

Fonte: Valores característicos dos reservatórios da CEEE

As usinas possuem restrições operacionais, de acordo com o tipo de turbina, a posição geográfica, as faixas de operações que evitam problemas e a potência nominal que define a vazão máxima turbinada (m^3/s).

Cada reservatório possui valores específicos para cada uma destas propriedades. Em operação, a defluência de um reservatório deve ser igual à sua afluência (aproximadamente), respeitando os limites de vertimento dos reservatórios subsequentes e a maximização da vazão turbinada (utilizada para gerar energia).

A operação dos reservatórios do rio Jacuí segue um programa diário, que entra em uma fase crítica quando se verifica uma situação de cheia. Tornam-se, então, necessários uma série de cuidados para controlar o nível dos reservatórios e do rio afetado. Sempre que o nível do reservatório atinge um determinado limite máximo torna-se necessário realizar vertimento pela abertura de comportas, sob o risco de comprometer a usina geradora. O controle da afluência nas usinas é feito por meio de medições de vazões afluentes da bacia hidrográfica de Passo Bela Vista, do nível dos reservatórios e da vazão defluente dos reservatórios. As medições de vazões afluentes são monitoradas, em tempo real, através do posto de medição Bela Vista.

3.1.1 Fatores condicionantes

Os fatores condicionantes caracterizam as restrições a serem consideradas na decisão de realizar vertimento pela abertura de comportas. Abrangem os elementos diretamente relacionados ao processo decisório, como também os fatores resultantes da decisão de realizar vertimento pela abertura de comportas. Os fatores condicionantes são:

- evitar danos às usinas geradoras: deve-se considerar a capacidade geradora da usina, para não enviar mais água do que o limite máximo suportado e controlar o nível do reservatório de modo a não permitir a inundação da usina;
- evitar prejuízos ao meio ambiente, populações ribeirinhas, pontes, navegação, estradas e portos devido à subida do nível dos rios afetados, que pode causar inundações;

- maximizar o aproveitamento de água para geração de energia: a água vertida pela abertura de comportas é desperdiçada, antes de realizar o vertimento por abertura de comportas deve-se elevar a geração de energia nas usinas de modo a obter o máximo aproveitamento da vazão afluyente;
- os fatores que determinam uma situação de cheia: são variáveis ambientais usadas na análise do ambiente do sistema hidrográfico, que definem a criticidade de uma determinada situação. Essas variáveis constituem os elementos utilizados na decisão de realizar ou não vertimento pela abertura de comportas, por isso, são os elementos incorporados no modelo de sistema especialista desenvolvido neste trabalho. Os fatores determinantes estão detalhados abaixo, no item 3.1.2.

3.1.2 Fatores determinantes

São os fatores que determinam uma situação de cheias, compreende os elementos utilizados na análise da criticidade de uma situação. Portanto, são os elementos que estão diretamente vinculados ao processo decisório de realizar vertimento pela abertura de comportas. Os fatores determinantes são:

- nível das precipitações no reservatório;
- nível das precipitações na bacia hidrográfica;
- nível do reservatório;
- vazão afluyente;
- variação da vazão no reservatório;
- vazão turbinada;
- vazão vertida.

O nível dos reservatórios, precipitação nos reservatórios, a vazão turbinada e gerada nas respectivas usinas são dados disponíveis na própria usina.

A precipitação na bacia hidrográfica de Passo Real é fornecida pela medição da precipitação em vários pontos da bacia, o que fornece uma idéia da precipitação como um todo na bacia hidrográfica. A determinação da precipitação na bacia hidrográfica é importante porque indica a vazão afluente no reservatório num instante próximo, pois a água que chega aos reservatórios provém da bacia hidrográfica de Passo Real.

Na figura 8 estão representados os pontos de medição da bacia hidrográfica de Passo Real: Passo Bela Vista, Espumoso, Ernestina, Capigui, Passo Real, Jacuí e Itaúba.

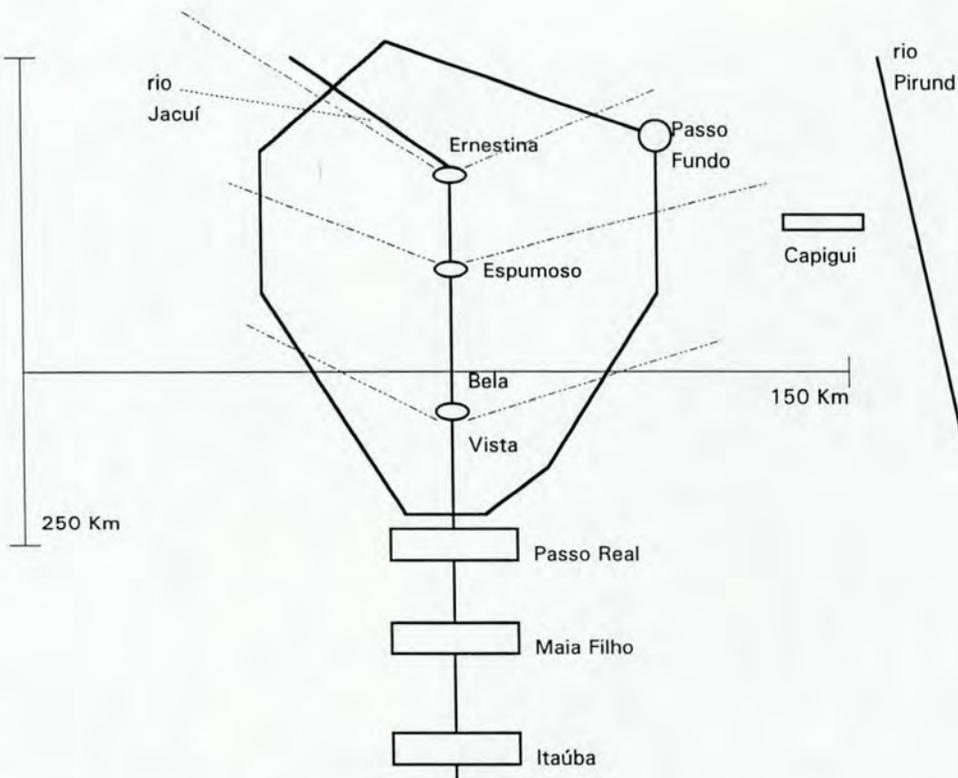


Figura 8 Bacia Hidrográfica Passo Real

3.1.3 Operação dos Reservatórios

A CEEE estabelece critérios para operação dos reservatórios do rio Jacuí, quando houver necessidade de vertimento ou, se este for iminente.

Foi adotado um critério de operação de comportas em níveis inferiores ao nível máximo operacional, visando compensar a diferença entre afluência e defluência durante o início da onda de cheia.

Devido à presença do rio Ivaí, afluente que encontra o Jacuí entre as barragens Maia Filho e Itaúba, há possibilidade de cheias isoladas no reservatório de Itaúba, que recebe tratamento em critério específico para sua operação em cheias isoladas.

Os aspectos energéticos, ligados ao controle de cheias, são abordados nas diretrizes eletro-energéticas semanais emitidas pela SPO/DOS (Seção de Programação da Transmissão / Departamento de Operações do Sistema CEEE).

Visando agrupar os procedimentos segundo o grau de criticidade da operação, são considerados cinco regimes de operação:

a) Regime Normal: utiliza-se o programa diário de operação.

b) Regime de Iminência de Vertimento ou Alerta: há necessidade de elevar a defluência, sem utilizar vertimento no reservatório de Passo Real.

c) Regime de Vertimento: há necessidade de vertimento no reservatório de Passo Real, porém respeitando as taxas de abertura entre manobras consecutivas e o intervalo mínimo entre elas.

d) Regime de Emergência: há necessidade de vertimento no reservatório de Passo Real, sem necessidade de respeitar as taxas de abertura entre manobras consecutivas e o intervalo entre elas.

e) Regime de Rebaixamento: restabelecimento do volume máximo normal do reservatório de Passo Real.

O regime de operação é determinado pelo nível do reservatório e pela sua vazão afluente. A significância dessas medidas varia de acordo com a época do ano, se é período seco ou chuvoso.

3.2 Adequação do problema à técnica de Sistemas Especialistas

Levantou-se as características do problema em questão para verificar se o mesmo se adequava a técnica de SE. Vários itens foram considerados. Chegou-se à conclusão que o problema se enquadrava em muitas das características consideradas necessárias à utilização de SE:

* O problema envolve a utilização de conhecimento especializado, pode-se verificar que um especialista nesta função leva tempo a ser formado, pois o conhecimento necessário é, em sua maior parte, adquirido pela experiência prática. O conhecimento mais formalizado diz respeito às medidas de níveis dos reservatórios, capacidades de armazenamento e geração turbinada. É um conhecimento técnico, disponível nos manuais de operação. Porém, os dados necessários para avaliar-se a gravidade de uma situação de cheias vão além destes mais formalizados, dependem de uma considerável experiência neste tipo de situação, isto é, envolvem o uso de heurísticas.

* A disponibilidade de especialistas no assunto, operadores da CEEE, para o desenvolvimento do sistema, aliada às características extremamente empíricas do problema e os procedimentos pouco rotineiros na sua solução, indicam uma aplicação coerente com as técnicas de IA, mais diretamente a SE.

* O fato do problema ser bem delimitado, com um grau de complexidade considerável, mas plausível de solução, o grande número de possibilidades a serem avaliadas na sua solução, e a inexistência de uma solução algorítmica. O elevado número de combinações a serem avaliadas torna inviável o desenvolvimento de uma solução computacional procedural.

O SE pode ser de utilidade para prática diária, nas situações de simulações onde se queira verificar as consequências dada a ocorrência de algum evento. Por exemplo, considerando-se uma determinada situação e a previsão de fortes chuvas na bacia hidrográfica, pode-se fornecer essas variáveis ao sistema para uma análise de possível situação futura. O SE pode também ser útil para a disseminação do conhecimento especializado entre os operadores mais inexperientes.

4 METODOLOGIA

Este capítulo descreve a metodologia utilizada neste trabalho. O trabalho foi realizado no Departamento de Operações do Sistema (DOS), na CEEE, envolvendo diretamente os setores SPO (Seção de Programação da Transmissão) e COS (Centro de Operações do Sistema).

A descrição que se segue aborda as seguintes etapas, inicialmente a fase de engenharia de conhecimento, o desenvolvimento do ambiente computacional, o sistema SECOX-HI, Sistema Especialista Conexcionista Híbrido, e a seguir, a confecção da base de casos e da base de testes.

4.1 Engenharia de Conhecimento no problema CEEE

As técnicas utilizadas para aquisição de conhecimento constituíram-se de entrevistas, análise de informações e construção dos grafos de conhecimento [LEA90].

A etapa inicial da aquisição de conhecimento foi através de entrevistas com os especialistas, e pelo estudo dos manuais e das diretrizes para controle de cheias nos reservatórios do sistema JACUÍ. Participaram como especialistas neste trabalho dois engenheiros da CEEE, Jairo Nehme dos Santos e Jaime Jeffman Filho.

As entrevistas foram realizadas no período de julho de 1993 a janeiro de 1994, em média duas vezes por semana. O tempo de duração de cada entrevista era de, aproximadamente, uma hora. Ao total, foram realizadas 48 entrevistas. Não foram realizadas gravações, apenas anotações. As entrevistas iniciais, aquelas ocorridas entre junho e agosto de 1993, caracterizaram-se por serem meramente exploratórias. Deste trabalho inicial resultou um esboço do problema a ser considerado, conforme mostra a figura 9.

A partir desta fase, foi possível classificar e definir os elementos (objetos) que compunham o domínio da aplicação. Estes objetos foram divididos em duas classes, a classe *diagnósticos* e a classe *evidências*.



Figura 9 Fluxo para diagnosticar os regimes de operação

A classe *diagnósticos* compreende as hipóteses a serem consideradas, isto é, o elenco de classificações que o sistema objetiva solucionar. A classe *evidências* compreende os objetos elementares da aplicação, que determinam a detecção de certos diagnósticos. Uma vez identificadas as classes de objetos, as entrevistas tornaram-se mais direcionadas, a fim de determinar-se todos os objetos que pertenciam a cada classe.

A próxima etapa na aquisição de conhecimento foi a utilização da técnica de grafos de conhecimento. O método para obtenção dos grafos de conhecimento, baseado em [LEA90] está descrito no quadro abaixo:

Metodologia de aquisição de conhecimento por Grafos de Conhecimento [LEA90]:

Fase 0 - Definição

1. Definir o escopo do problema.
2. Definir as hipóteses de diagnóstico que farão parte do projeto.
3. Definir uma lista de sintomas, sinais e resultados de testes, com a assistência de um especialista.

Fase 1 - Aquisição de Conhecimento

1. Selecionar, sem conhecimento prévio do especialista, uma das hipóteses de diagnóstico, se possível em ordem decrescente de frequência de ocorrência.
2. Pedir para o especialista indicar, na lista de sintomas, os itens necessários para a formulação das hipóteses diagnósticas, definindo, assim, um subconjunto de trabalho.
3. Pedir para o especialista ordenar o subconjunto de trabalho de acordo com a importância dos itens para o diagnóstico.
4. Pedir para o especialista assumir os itens da lista ordenada como nodos de evidência de um grafo de conhecimento e associá-los, de forma a tornar possível a conclusão sobre a hipótese diagnóstica (gerando nodos intermediários que convergem para a hipótese de diagnóstico).
5. Pedir para o especialista determinar um grau de importância entre 0 e 10 para a informação representada em cada nodo do grafo.
6. Pedir para o especialista definir os operadores lógicos (E,OU,NÃO) associados aos nodos do grafo.
7. Repetir o processo para outras hipóteses de diagnóstico, formando uma família de grafos.

Figura 10 Quadro descritivo da metodologia de construção dos grafos de conhecimento

4.1.1 Construção dos Grafos de Conhecimento

Os grafos de conhecimento fornecem um mapeamento claro e coerente das relações entre as classes *diagnósticos* e *evidências*. Indicam que evidências contribuem para quais diagnósticos, e possibilitam a quantificação desta contribuição.

Dessa forma, os grafos de conhecimento permitem a representação de associações de evidências que apontam para os diagnósticos, associações estas que espelham o raciocínio do especialista humano, quando da formulação do diagnóstico. A quantificação destas associações é importante para aferir-se um grau de aceitabilidade para a hipótese diagnóstica formulada, bem como para justificá-la.

De acordo com a metodologia de construção dos grafos de conhecimento foi elaborada uma lista, com todos elementos que compõem as classes do domínio da aplicação. As listas foram elaboradas juntamente com os especialistas, durante as entrevistas. Uma vez determinado o objetivo do sistema, detecção dos regimes de operação dos reservatórios, passou-se a considerar os elementos usados pelos especialistas na avaliação desses regimes.

Os elementos da classe *diagnóstico*, ou seja, a classificação dos regimes de operação, encontram-se descritos nas "Diretrizes para Controle de Cheias nos Reservatórios do Sistema Jacuí", emitidas pela SPO/DOS, citados no item 3.1.3.

A lista completa dos elementos das classes *diagnósticos* esta relacionada abaixo:

- 1 - Operação em regime de **emergência**;
- 2 - Operação em regime de **vertimento**;
- 3 - Operação em regime de **alerta**;
- 4 - Operação em regime **normal**;
- 5 - Operação em regime de **rebaixamento**.

Como o objetivo do sistema proposto é tratar das situações mais críticas, envolvendo cheias, considerou-se no domínio da aplicação apenas os regimes de operação aplicados nestas situações, os regimes de **alerta**, **vertimento** e **emergência**.

Os elementos da classe *evidências* foram determinados através das entrevistas com os especialistas, onde eram feitas perguntas do tipo: "Como determina

uma situação como sendo de um certo regime?", ou "Porque determinada situação se enquadra num regime e não em outro?". Perguntas desse tipo foram feitas para todos os regimes de operação considerados no domínio do sistema. Analisando-se as respostas fornecidas foi possível, em conjunto com os especialistas, determinar os elementos utilizados para a classificação dos regimes de operação.

As evidências que compõem a classe *evidências* são:

- 1 - Variação da vazão;
- 2 - Precipitação no reservatório de Passo Real;
- 3 - Precipitação na bacia hidrográfica;
- 4 - Vazão afluente;
- 5 - Defluência turbinada e vertida;
- 6 - Nível do reservatório.

A classe *evidências* compreende, não apenas uma determinada evidência, mas os atributos relacionados a esta. Estes atributos, via de regra, foram descritos pelos especialistas na forma de predicados do tipo ALTO, MÉDIO, BAIXO ou MÍNIMO, NORMAL, MÁXIMO, conforme a sua significância para a determinação de uma situação de cheias

Para exemplificar, pode-se considerar a evidência *precipitação*. Uma *precipitação* de 70 mm/dia é altamente significante para uma situação de cheias, pois implica numa considerável quantidade de água a chegar nos reservatórios. Desse modo, uma *precipitação* com valor próximo ou maior que 70 mm/dia é considerada uma *precipitação alta*. À medida que a intensidade da *precipitação* diminui, sua relevância para uma situação de cheias também diminui, e ela passa a ser classificada como *média* ou *baixa*, dependendo do valor medido.

As notações relativas às evidências são:

- a) $m^3/s/h$, metros cúbicos por segundo por hora, para variação da vazão;
- b) mm/dia, milímetros de precipitação por dia, para precipitações;

- c) m^3/s , metros cúbicos por segundo, para medidas de vazão;
- d) m, metros, para medidas de nível de reservatório.

A lista completa dos objetos que compõem a classe evidências encontra-se no anexo A.

Conforme a metodologia de construção dos grafos de conhecimento, a próxima etapa do trabalho foi a determinação das relações entre os elementos das classes *evidências* e *diagnósticos*. A construção dos grafos foi feita durante as entrevistas com o engenheiro Jairo dos Santos. Estas entrevistas ocorreram durante os meses de novembro de 1993 a janeiro de 1994.

De posse das listas de *diagnósticos* (regimes de operação) e *evidências*, solicitou-se ao especialista Jairo dos Santos que elaborasse uma lista com aqueles elementos da classe *evidências* cuja ocorrência contribui para a formulação da hipótese diagnóstica de cada um dos elementos da classe *diagnósticos*.

Como resultado desse trabalho, obteve-se uma lista composta por um conjunto de evidências, para cada um dos diagnósticos considerados no domínio da aplicação. Solicitou-se então, ao especialista, que ordenasse as listas de acordo com a importância que tinham para a definição diagnóstica. Utilizando-se a lista ordenada como linha de base de um grafo, desenhou-se as associações de evidências utilizadas para a conclusão diagnóstica. De posse das listas de evidências e suas associações, em uma escala de 0 a 10, atribuiu-se um peso para cada uma das evidências selecionadas (nodos de entrada do grafo) e para as suas associações (nodos intermediários do grafo). Formou-se assim, um grafo de conhecimento para determinada hipótese.

As listas ordenadas de evidências, com seus respectivos pesos, estão relacionadas no anexo B, para os regimes de operação de **emergência**, **vertimento** e **alerta**. Estes regimes de operação constituem os objetos da classe diagnóstico considerados no sistema **SECOX-HI**, pois representam as situações críticas, nas quais pode-se chegar a uma situação de cheias.

Para exemplificar, estão relacionadas abaixo algumas evidências e seus respectivos grafos de conhecimento colhidos dos especialistas para as hipóteses de diagnóstico regime de **emergência**, **vertimento** e **alerta**.

As evidências consideradas para o diagnóstico regime de **emergência** são:

- E1 - nível do reservatório acima de 0.50 m;
- E2 - nível do reservatório entre 0.40 e 0.50 m;
- E3 - vazão afluente alta em PBV, acima de 1500 m³/s;
- E4 - defluência vertida baixa, menos de 500 m³/s;
- E5 - variação alta da vazão;
- E6 - precipitação alta na bacia hidrográfica - dia atual.

Os grafos de conhecimento relacionados às evidências E1 a E6 estão apresentados a seguir:

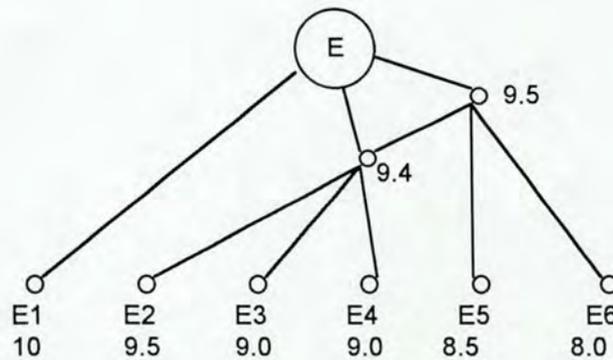


Figura 11 Grafos de conhecimento para regime de emergência

As evidências consideradas para o diagnóstico regime de **vertimento** são:

- E1 - nível do reservatório entre -1.27 e 0.00 m;
- E2 - nível do reservatório entre -1.40 e -1.27 m;

E3 - vazão afluente alta PBV, acima de 1200 m³/s;

E4 - variação alta da vazão;

E5 - vazão afluente média PBV, entre 500 e 1200 m³/s.

Os grafos de conhecimento relacionados às evidências E1 a E5 estão apresentados a seguir:

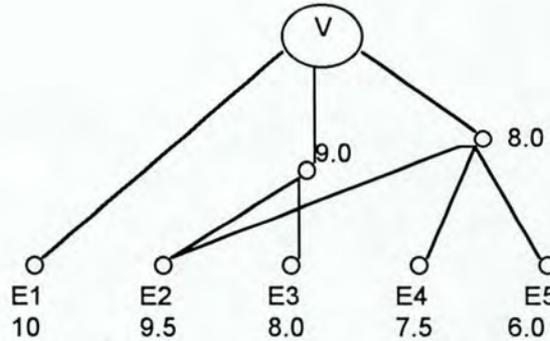


Figura 12 Grafos de conhecimento para regime de vertimento

As evidências consideradas para o diagnóstico regime de **alerta** são:

E1 - nível do reservatório entre -1.40 e -1.27 m;

E2 - vazão afluente alta PBV, acima de 500 m³/s;

E3 - precipitação alta na bacia hidrográfica - dia atual;

E4 - defluência turbinada baixa;

E5 - vazão afluente média PBV, entre 300 e 500 m³/s.

Os grafos de conhecimento relacionados às evidências E1 a E5 estão apresentados a seguir:

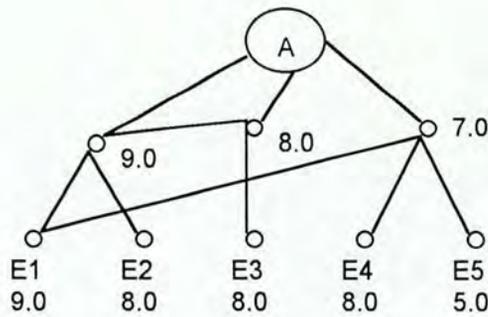


Figura 13 Grafos de conhecimento para regime de alerta

Ao total foram colhidos 98 grafos, sendo 47 referentes ao regime de **emergência**, 24 referentes ao regime de **vertimento** e 27 ao regime de **alerta**. No anexo C estão incluídos outros grafos colhidos dos especialistas.

4.1.2 As Variáveis Nebulosas

A formulação dos diagnósticos para o problema CEEE depende da avaliação dos objetos da classe *evidências*. Esses objetos, relacionados no anexo A, representam, na sua maior parte, variáveis ambientais, para as quais o especialista associou predicados.

Não existe um formalismo preciso para se atribuir um predicado (ou atributo) a certas evidências. O especialista toma essa decisão baseado, em grande parte, na sua experiência, na verificação de situações passadas e no bom senso. Em suma, no seu conhecimento heurístico. Por esta razão, os mesmos valores para as mesmas evidências podem receber predicados distintos, por diferentes especialistas. Na tomada de decisão, é necessário avaliar-se a relação entre estes predicados imprecisos, e definir o que e o quanto eles significam.

A evidência *variação de vazão*, por exemplo, pode assumir três predicados, *alta*, *média* e *baixa*. Cada um desses predicados pode ter um grau de importância distinto, dependendo do diagnóstico associado. O problema encontrado nesse tipo de situação é determinar quando a evidência deve ser classificada como *alta*, *média* ou *baixa*, e o quanto *alta*, o quanto *média* e o quanto *baixa*.

Deve-se considerar, também, que a passagem entre esses conceitos não ocorre de forma abrupta, mas sim, gradualmente. Na evidência *variação de vazão*, não existe um ponto onde esta deixa de ser *baixa* e, imediatamente após, torna-se *média*. Na realidade, a evidência torna-se menos *baixa* à medida que o valor a ela associado aumenta, tornando-se assim, cada vez mais *média*. Até um ponto onde ela possa ser considerada totalmente *média*. O problema então, passa a ser a determinação desses pontos, no espectro de ocorrência dos conceitos.

A figura 14 exemplifica a relação da evidência *variação de vazão* com seus atributos. Os valores são fornecidos pelo especialista.

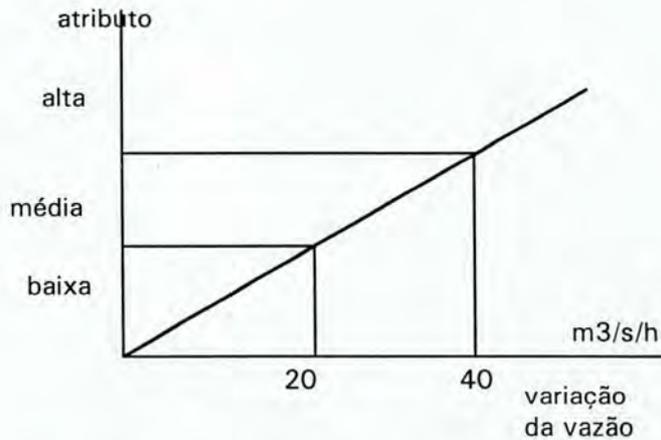


Figura 14 Relação entre *variação de vazão* e seus atributos

Pode-se verificar, pela figura 14, os intervalos de classificação para *variação de vazão*. Uma interpretação errônea do gráfico da figura é assumir que no ponto 20, por exemplo, a evidência deixa de ser *baixa* a passe a ser, automaticamente, *média*. Existe uma zona de transição, onde a evidência pode pertencer a mais de um conjunto nebuloso (atributo). Diz-se então, que a evidência é uma variável nebulosa (*fuzzy*), portanto pode-se aplicar os princípios da teoria dos conjuntos nebulosos para se determinar o grau de pertinência de determinado valor aos conjuntos de atributos da evidência.

O grau de pertinência em um conjunto nebuloso é definido por uma função, a *função de pertinência* [VIO93]. A determinação da função de pertinência

para um conjunto nebuloso é feita pelo especialista, pela marcação de pontos em um gráfico cartesiano. O eixo "x", horizontal, define o intervalo de domínio de um conjunto nebuloso. O eixo "y", vertical, assume valores que quantificam a pertinência, normalmente num intervalo de 0 a 1. Pela marcação de pontos no gráfico, determina-se uma figura que corresponde a uma função que expressa a pertinência em um conjunto nebuloso. Quanto mais simples for a figura formada no gráfico, mais simples será a implementação da função de pertinência. Se a figura for indefinida e não existir uma função matemática a ela associada, usualmente, calcula-se o grau de pertinência pela integração de áreas.

Com exceção da evidência *nível do reservatório de Passo Real*, as demais evidências tiveram predicados associados pelo especialista. O nível do reservatório, dado pela medida do nível em metros, é um valor discreto para o qual o especialista não atribui predicados. As evidências *variação de vazão*, *defluência vertida e turbinada*, *precipitações* e *vazão afluente* tiveram predicados associados, pelo especialista, aos seus valores. Portanto, solicitou-se ao especialista Jairo dos Santos que traçasse no gráfico cartesiano os pontos do domínio para cada uma das evidências citadas acima, a fim de determinar suas respectivas funções de pertinência

As funções de pertinência dos conjuntos nebulosos no problema de detecção de regime de operação formaram trapezóides, quando traçadas no gráfico cartesiano. Portanto, a função de cálculo de área de trapézio corresponde à função de pertinência dos conjuntos nebulosos no problema considerado.

Estão relacionados abaixo as evidências *variação de vazão*, *defluência vertida e turbinada*, *precipitações* e *vazão afluente*, que constituem os conjuntos nebulosos no problema de detecção de regime de operação, com seus atributos, os valores que os definem, e as figuras plotadas no eixo cartesiano. Além disso, existe uma quádrupla que representa os pontos do eixo cartesiano que definem um atributo de evidência (vértices dos trapezóides).

O primeiro ponto significa o ponto no qual o atributo começa a ser considerado, antes desse ponto sua ocorrência recebe o valor zero; o segundo ponto indica que ali o atributo passa a ser considerado total, sua ocorrência recebe valor um; o terceiro ponto indica onde o atributo começa a diminuir, ou seja, deixa de ser

considerado total; o quarto ponto indica o alcance máximo do atributo, acima deste sua ocorrência recebe o valor zero. Nos casos de extremo, como o conceito *alta* entre os atributos *baixa*, *média* e *alta*, o quarto ponto do atributo *alta* pode simplesmente significar um ponto de final para o intervalo, por ser considerado suficientemente alto. O exemplo da evidência *variação de vazão* ilustra esse fato. O conceito de *variação de vazão alta* tem seu ponto maior no valor 500, apenas para efeito matemático, de limites no intervalo, já que a *variação de vazão* nunca atinge essa marca.

1 Variação da vazão:

1.1 Alta - acima de 40 m³/s/h - pontos(35,45,500,500)

1.2 Média - entre [20;40] m³/s/h - pontos(15,25,35,45)

1.3 Baixa - abaixo de 20 m³/s/h - pontos(-100,-100,15,25)

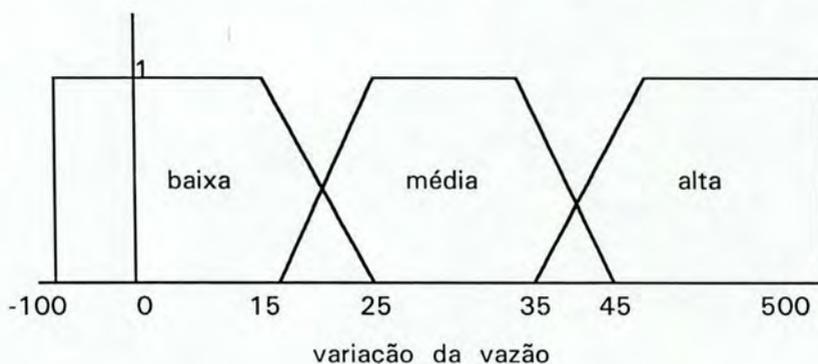


Figura 15 Gráfico da função de pertinência para variação de vazão

2 Precipitações:

2.1 Alta - acima de 50 mm/dia - pontos(45,60,100,100)

2.2 Média - entre [20;50] mm/dia - pontos(15,25,45,60)

2.3 Baixa - menos de 20 mm/dia - pontos(0,0,15,25)

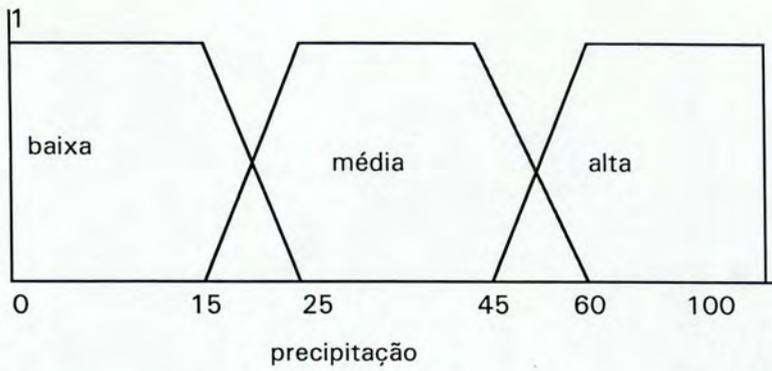


Figura 16 Gráfico da função de pertinência para precipitação

3 Defluência turbinada:

3.1 Alta - acima de 200 m³/s - pontos(190,230,400,400)

3.2 Média - entre [100;200] m³/s - pontos(95,110,190,230)

3.3 Baixa - menos de 100 m³/2 - pontos(0,0,95,110)

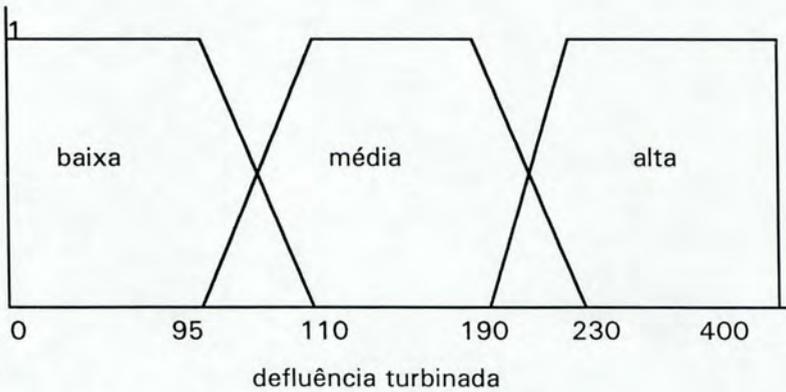


Figura 17 Gráfico da função de pertinência para defluência turbinada

4 Defluência vertida:

4.1 Alta-acima de 1500 m³/s - pontos(1450,1550,3000,3000)

4.2 Média-entre[500;1500]m³/s - pontos(450,550,1450,1550)

4.3 Baixa - menos de 500 m³/s - pontos(0,0,450,550)

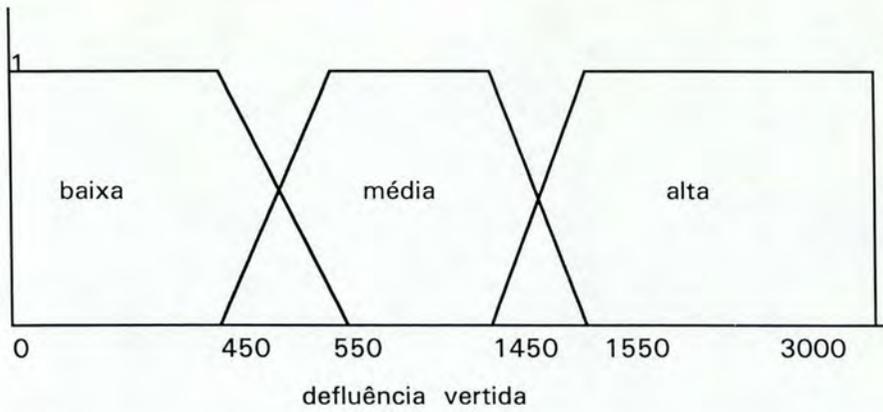


Figura 18 Gráfico da função de pertinência para defluência vertida

5 Afluência PBV para regime de vertimento:

5.1 Alta-acima de 1200 m³/s - pontos(1000,1250,1500,1500)

5.2 Média-entre [500;1200]m³/s- pontos(450,550,1000,1250)

5.3 Baixa - menos de 500 m³/s - pontos(0,0,450,550)

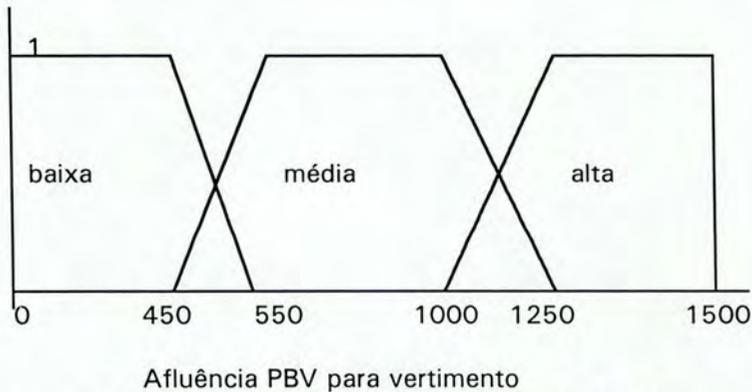


Figura 19 Gráfico da função de pertinência para afluência PBV para vertimento

6 Afluência PBV para regime alerta:

6.1 Alta - acima de 500 m³/s - pontos(450,600,1000,1000)

6.2 Média-entre [300;500] m³/s - pontos(250,350,450,600)

6.3 Baixa - menos de 300 m³/s - pontos(0,0,250,350)

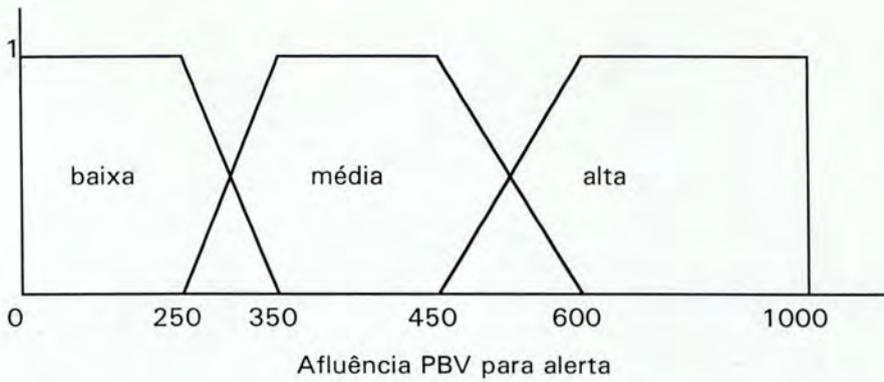


Figura 20 Gráfico da função de pertinência para afluência PBV para alerta

7 Afluência PBV para regime de emergência

7.1 Alta-acima de 1500 m³/s - pontos(1450,1600,3000,3000)

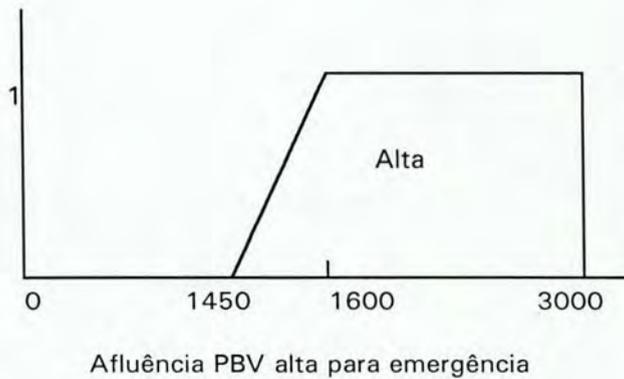


Figura 21 Gráfico da função de pertinência para afluência PBV para emergência

4.2 A Representação do Conhecimento

Conforme descrito no item 2.9, o sistema **HYCONES** utiliza duas entidades abstratas para representar o conhecimento do domínio: *diagnósticos* e *achados*. A mesma estrutura foi utilizada no sistema **SECOX-HI**. O modelo relacional foi utilizado para representar os frames de diagnósticos e de evidências. No **HYCONES**, os frames de *achados* são descritos por um conjunto específico de

atributos, definidos de acordo com o conhecimento do domínio, os frames de *diagnósticos* são utilizados para armazenar as descrições do conhecimento necessário para resolver o problema diagnóstico da aplicação. Um frame de diagnóstico armazena referências a conjuntos de achados que, quando presentes, influenciam sua detecção [REA93].

O **HYCONES** emprega 4 tipos de *slots* na descrição de um frame diagnóstico:

Gatilho: referencia um achado que, quando presente, aponta o diagnóstico por ele referenciado como solução potencial para o caso apresentado.

Achados-essenciais: achados que, quando presentes, asseguram a identificação do diagnóstico referenciado pela lista de achados.

Achados-complementares: achados que auxiliam na confirmação da hipótese de que o diagnóstico referenciado pela lista de achados é a solução do problema.

Achados-de-negação: achados que, quando presentes, tendem a eliminar o diagnóstico referenciado pela lista de achados como solução do problema.

Dessa forma, a ligação entre os frames de *achados* e *diagnósticos* faz-se por meio das referências aos frames de *achados* existentes nos frames de *diagnóstico*.

O **SECOX-HI** utiliza estruturas de dados relacionais para incorporar as funções realizadas pelos frames no **HYCONES**, ou seja, para a representação simbólica do conhecimento.

A representação de conhecimento baseada nas estruturas relacionais faz-se em dois níveis, o nível de *evidências* e o nível de *diagnósticos*. O nível de *evidências* representa os objetos da aplicação que contribuem para a ocorrência de certos diagnósticos. O nível *diagnósticos* representa os problemas de classificação que o sistema objetiva solucionar. Ambos os níveis estão representados na base de

conhecimento por estruturas distintas. A figura 22 exemplifica as classes pertencentes ao domínio da aplicação.

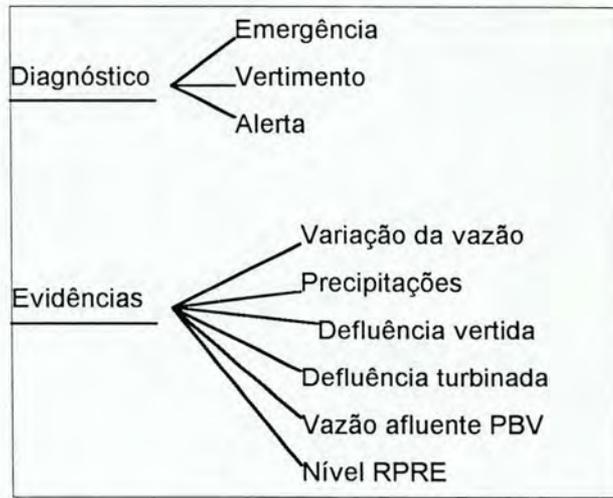


Figura 22 As classes diagnósticos e evidências

As estruturas de dados para o nível diagnóstico são utilizadas para armazenar os elementos da classe *diagnósticos*, além disso, uma estrutura de diagnóstico relaciona-se a conjuntos de evidências que, quando presentes, contribuem para sua detecção. A relação entre as estruturas de diagnósticos e evidências faz-se por meio de uma estrutura intermediária, que relaciona as evidências ao diagnóstico associado a elas. A cada relação de uma evidência a um diagnóstico está associado um valor, que representa a relevância da evidência para a solução apontada pelo diagnóstico relacionado. A relação entre diagnósticos e evidências é do tipo *n-n*, ou seja, várias evidências apontam para um determinado diagnóstico e, uma mesma evidência pode estar relacionada a mais de um diagnóstico. Por exemplo, a evidência *variação alta da vazão* se relaciona aos diagnósticos operação em regime de **emergência**, regime de **vertimento** e regime de **alerta**.

A figura 23 mostra um frame de diagnóstico em **HYCONES** para regime de emergência.

Frame diagnóstico: emergência	
Gatilho:	nível > de 0.50
Achados	afluência PBV alta
Essenciais:	variação da vazãalta
Achados	precipitação alta na
Complementares:	bacia hidrográfica

Figura 23 Frame diagnóstico

A figura 24 mostra as estruturas relacionais no **SECOX-HI**, correspondente ao frame diagnóstico da figura 23.

Na figura 24 estão representadas três estruturas de dados. A estrutura “diagnósticos” armazena os elementos da classe *diagnósticos*. Nesta estrutura, cada elemento da classe diagnóstico possui um identificador associado, são os elementos *d1*, *d2*, *d3* da figura. A estrutura “evidências” armazena os elementos da classe *evidências*, que por sua vez, também possuem um identificador associado, representado na figura pelos elementos *e1*, *e2*, *e3*, etc.

A ligação entre as estruturas de diagnósticos e evidências faz-se por meio da referência a uma outra estrutura, interna ao sistema, que está associada a um elemento da estrutura de diagnósticos, por meio do identificador do elemento diagnóstico considerado. Esta estrutura, representada na figura 24 pelo identificador *d1*, para diagnóstico regime de **emergência**, armazena as evidências que, quando presentes, apontam o diagnóstico como solução do problema proposto. Além disso, a estrutura também armazena um valor associado a cada evidência, que indica a importância da evidência para o diagnóstico por ela referenciado. Fazendo-se uma analogia com as estruturas de frames do **HYCONES**, o fator de importância das evidências cumpre a função realizada pelos *slots* dos frames. A importância *10*, por exemplo, associada à evidência *nível >0.50*, indica que esta evidência representa o gatilho para o diagnóstico regime de **emergência**, pois quando presente indica o regime de **emergência** como solução potencial ao problema.

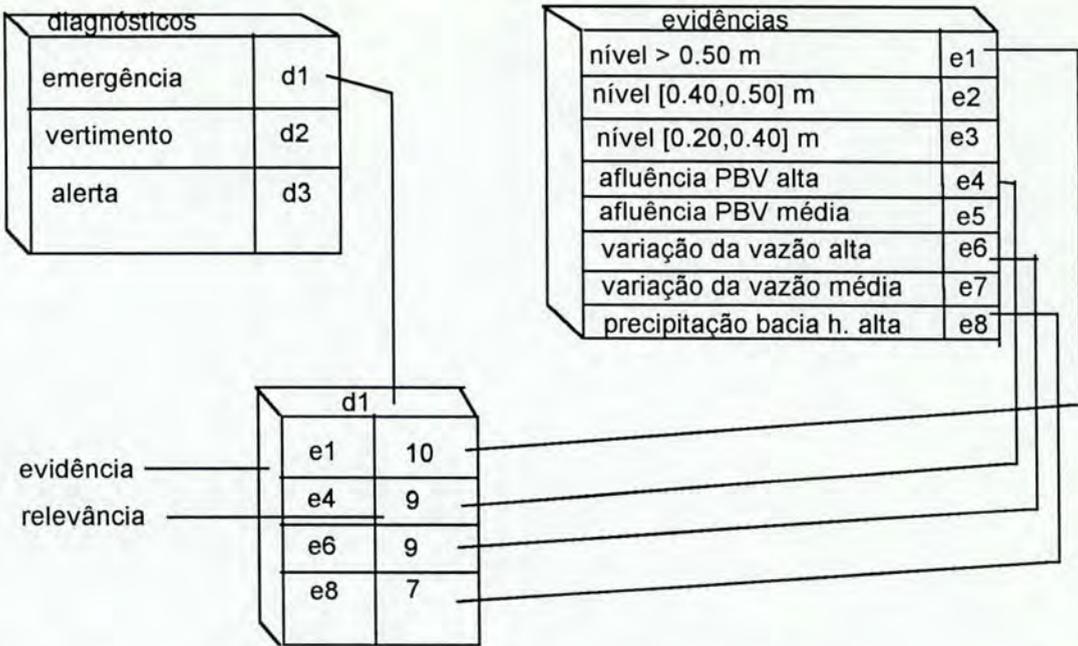


Figura 24 Estruturas relacionais para associação diagnósticos/evidências

Relacionando-se as estruturas de evidências e diagnósticos, da maneira descrita acima, faz-se com que o formalismo de representação de conhecimento simbólico abranja todo o espectro da aplicação.

A estrutura de dados para o nível *evidências* é formada por um conjunto de evidências, seu tipo e seus atributos. Os atributos são definidos de acordo com o conhecimento do domínio. Uma evidência pode ser considerada, para efeito semântico, em dois tipos: *discreta* ou *nebulosa*.

Considera-se uma evidência do tipo *discreta* quando esta assume valores 1 e 0 em relação a seus atributos, isto é, um atributo é totalmente associado à evidência ou não é associado. A evidência *nível do reservatório* exemplifica esta situação. O nível do reservatório nunca assume dois valores simultaneamente, pois se o reservatório está em um nível, não pode estar em nenhum outro naquele instante.

Uma evidência é considerada do tipo *nebulosa* (ou *difusa*) quando pode assumir mais de um de seus atributos simultaneamente, nesse caso, os valores que quantificam a relação da evidência com seus atributos pertencem ao intervalo [0,1]. A

associação de evidências com seus atributos é representada por uma relação de estruturas de atributos e evidências.

A figura 25 exemplifica a estrutura relacional para a classe evidências e sua associação com os respectivos atributos:

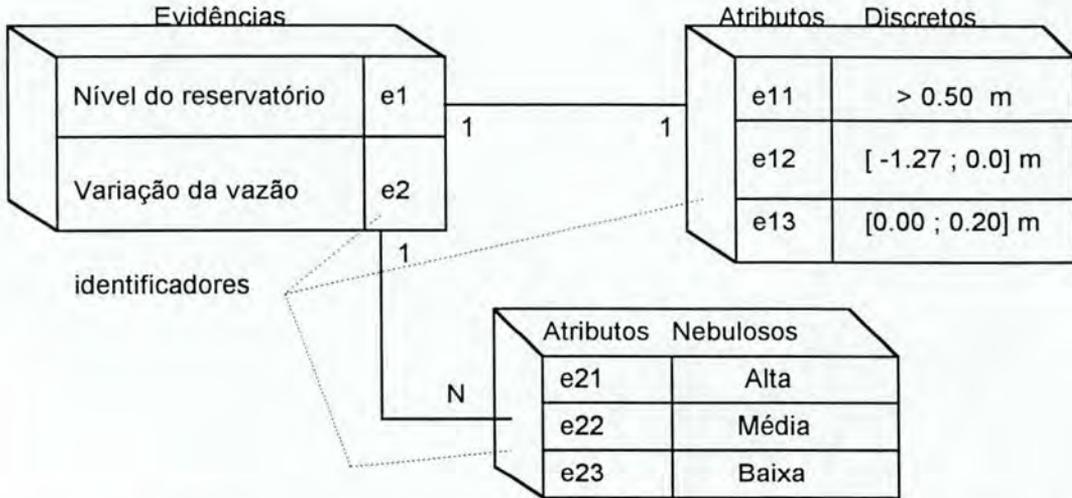


Figura 25 Relação das estruturas de evidências e atributos

Na figura 25 estão representadas três estruturas que, juntas, representam os elementos da classe *evidências*. Através dos elementos *identificadores* de cada estrutura, acessa-se os atributos de cada evidência. Esta associação sempre é realizada a partir da estrutura “evidências”. Os mesmos elementos *identificadores* são utilizados para fazer as associações de evidências com diagnósticos, conforme descrito anteriormente neste item.

4.2.1 A integração entre as redes neurais e o paradigma simbólico

O conhecimento representado pelas estruturas relacionais é transmitido para as redes neurais. O modelo conexionista adotado é o Modelo Neural Combinatório (CNM), descrito no capítulo 2.

O modelo para sistemas especialistas híbridos, **SECOX-HI**, é do tipo fracamente acoplado. A comunicação entre a parte simbólica e a conexionista é realizada através de arquivos de dados. Não existe, portanto, compartilhamento de estruturas de dados em memória. Cada uma das partes é executada em ambiente de hardware diferente, sob diferentes sistemas operacionais. Optou-se por esta configuração devido a dificuldade de executar o modelo neural MNC em um microcomputador, pela grande quantidade de memória principal necessária a sua execução.

A correspondência entre as estruturas do MNC e as estruturas de dados relacionais é baseada no mapeamento dos grafos de conhecimento para as redes neurais e para as estruturas relacionais, sob forma de arquivo de dados.

Como não existe compartilhamento de estruturas de memória entre o MNC e a parte simbólica, a tradução dos grafos de conhecimento para o MNC é feita via transferência de arquivos de dados. Traduz-se os grafos de conhecimento para uma estrutura que armazena combinações de evidências associadas a um determinado diagnóstico. Esta estrutura é implementada por uma lista com os graus de importância das evidências consideradas. Cada posição da lista indica uma evidência, e cada lista aponta para um diagnóstico. A figura 26 representa um grafo de conhecimento para o diagnóstico regime de **emergência**, sua tradução para uma estrutura relacional e sua transformação num arquivo para a rede neural.

A tradução do grafo de conhecimento para a estrutura relacional é feita agrupando-se os nodos que compõem cada sub-árvore do grafo. Estes são inseridos numa lista, da esquerda para a direita, com seus respectivos pesos, formando uma relação de *E-lógico* entre as evidências. Existe um elemento da lista, o último, que corresponde ao diagnóstico relacionado à lista. Esta estrutura é depois transformada em um arquivo com pesos, como mostra a figura 26, para leitura pelo modelo conexionista MNC. Tanto na estrutura que armazena as combinações de evidências como no arquivo a ser enviado ao MNC, as evidências são identificadas pelas suas posições. Evidências ausentes na lista são representadas com o valor zero na sua respectiva posição, caso contrário, a posição recebe o valor do peso normalizado da evidência.

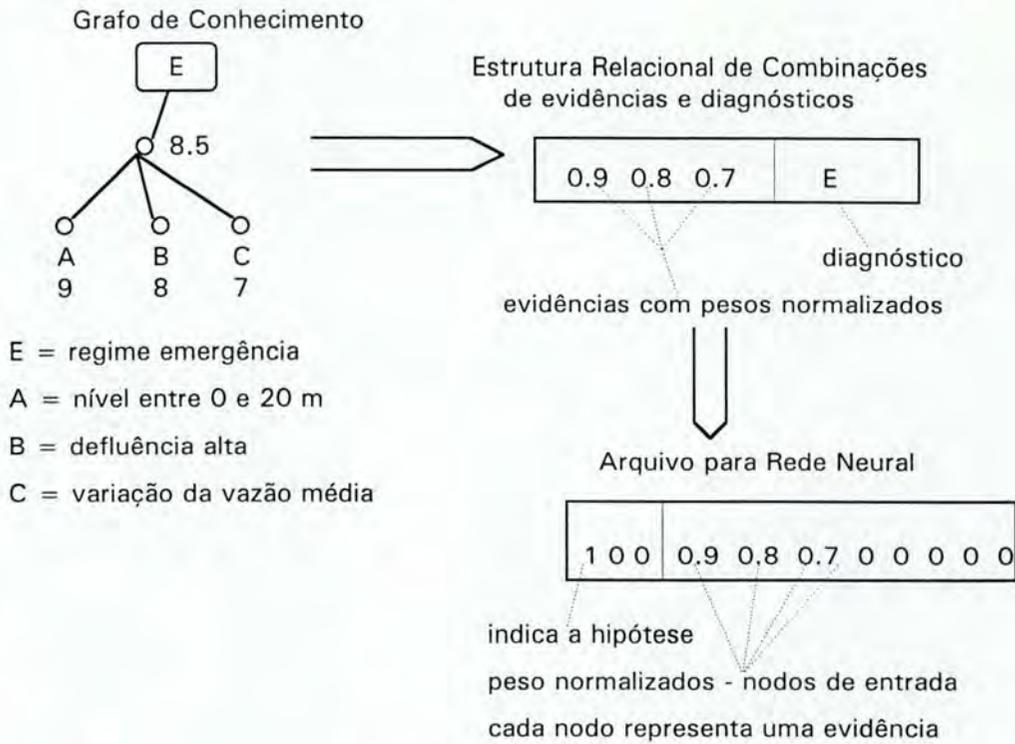


Figura 26 Mapeamento de um Grafo de Conhecimento para as estruturas simbólica e conexionista

4.3 O motor de inferência

Em SE híbridos, com alto grau de integração entre as partes simbólica e conexionista, caso dos modelos fortemente acoplados e modelos com integração total, o motor de inferência opera sobre ambas as formas de representação de conhecimento. O modelo descrito neste trabalho é classificado como fracamente acoplado, a inferência baseia-se no mecanismo de reconhecimento de padrões, implementado pelo modo de consulta do MNC, citado no item 2.7.

O motor de inferência não opera sobre a parte simbólica de representação de conhecimento. A principal função da parte simbólica relaciona-se à representação explícita do conhecimento e suporte ao mecanismo de explanação do MNC. Uma vez selecionado um conjunto de evidências, numa operação de consulta, a parte simbólica encarrega-se de transformar este conjunto de evidências num arquivo compreensível pelas redes neurais. Este arquivo é então apresentado às redes neurais, as quais

ativadas, passam a representar sinais de saída para cada um dos diagnósticos tratados pelo sistema.

Os caminhos, formados por conjuntos de evidências, que apresentam sinal de saída são apresentados pelas redes neurais, que indicam o caminho com maior sinal de saída como a solução do problema proposto.

A explanação, dessa forma, é realizada pela parte conexionista por racionalização, ou seja, o sistema procura convencer o usuário da validade da conclusão apresentada.

A figura 27 exemplifica o fluxo de inferência do modelo:

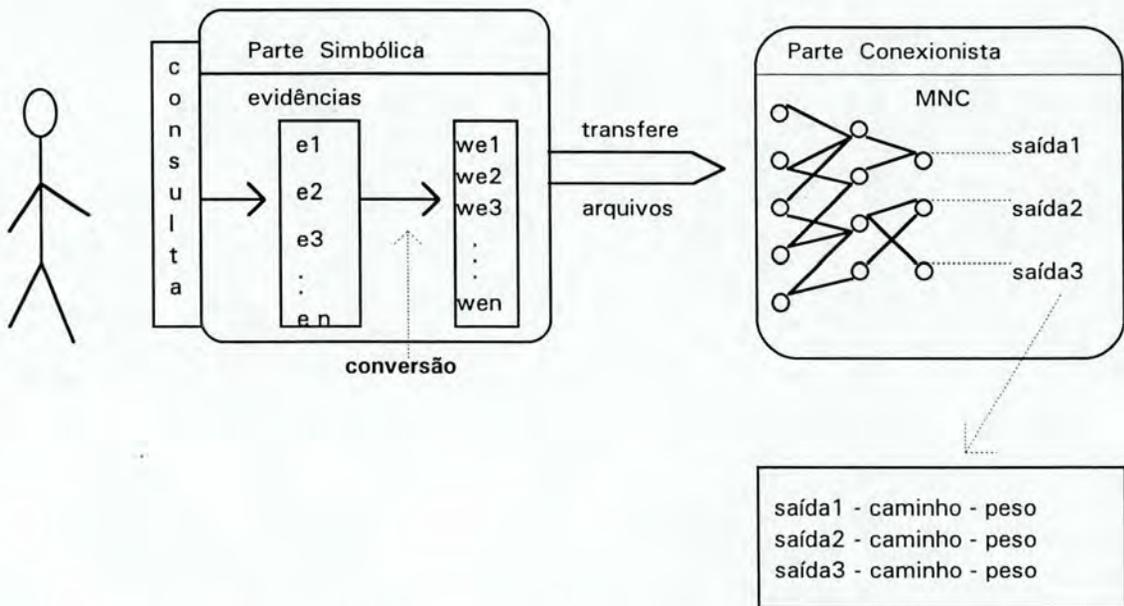


Figura 27 Fluxo de inferência do SECOX-HI

4.4 Aprendizagem

A máquina de aprendizado tem o propósito de adquirir conhecimento ou refinar o conhecimento armazenado na base de conhecimento, através de exemplos

contidos na base de casos [REA93]. A máquina de aprendizado do SECOX-HI executa o aprendizado indutivo, implementado pelo MNC.

A máquina de aprendizado indutivo possibilita dois tipos de aprendizado para as redes neurais: explicitação automática de conhecimento por casos de treinamento e aprendizado incremental. A explicitação automática de conhecimento visa sanar o problema da aquisição de conhecimento, o aprendizado incremental visa dotar o sistema de capacidade de aprendizado pela experiência [REA93].

A explicitação automática de conhecimento, a partir da base de casos, é executada em três etapas:

- criação de uma rede neural sem conhecimento prévio, com topologia baseada no MNC;
- treinamento da rede pelo algoritmo de punição e recompensa;
- normalização e eliminação de células não operantes da rede, através do algoritmo de poda e normalização.

O método para criação da rede neural baseia-se na análise dos casos da base de casos para gerar uma rede com certo conhecimento, onde são ligados aos nodos de hipótese apenas às evidências observadas para aquele diagnóstico em algum caso apresentado. Estas evidências são combinadas em grupo, conforme a ordem de combinação adotada, de dois e três no caso do modelo descrito aqui, de modo a esgotar a possibilidade de combinações entre eles.

Após a geração, a rede neural vazia é treinada a partir dos casos armazenados na base de casos. Este treinamento consiste na modificação dos pesos de cada conexão da rede neural, recompensando-se os ramos da rede que levam aos diagnósticos corretos e punindo os ramos da rede que levam a diagnósticos incorretos. O treinamento da rede neural dá-se pela aplicação do algoritmo de *Punição e Recompensa - versão Arranque* definido para o MNC [MAC91][REA93].

Este algoritmo produz uma rede treinada não operante, contendo acumuladores com valores entre $-n$ e $+n$, sendo “ n ” o número de casos. Abaixo é apresentado o algoritmo de *Punição e Recompensa - versão Arranque* [REA93]:

Para cada exemplo da base de casos, executar o seguinte procedimento:

- propagar os sinais de entrada até a camada de hipótese;
- para cada arco que alcance algum nodo de hipótese, fazer:

Se o nodo de hipótese alcançado corresponde a um resultado correto:

Então, propagar retroativamente, a partir deste nó até os nós de entrada um acréscimo no valor do acumulador de recompensas, conforme a fórmula:

$$FE * AD * IE$$

onde:

FE = fluxo evidencial,

AD = a ativação do neurônio de destino,

IE = a importância do exemplo para o treinamento.

Se não, propagar retroativamente um acréscimo no valor do acumulador de punições deste nodo até os nodos de entrada, conforme a fórmula:

$$FE * AD * IE$$

onde:

FE = fluxo evidencial,

AD = a ativação do neurônio de destino,

IE = a importância do exemplo para o treinamento.

Para transformar a versão treinada e não-operante da rede neural em versão operante, aplica-se o algoritmo de *Poda e Normalização* à rede [MAC91][REA93]. Este algoritmo tem por objetivo transformar os acumuladores de punição e recompensa da rede neural em pesos de conexão no intervalo $[0,1]$ e

remover arcos da rede cujos pesos sejam menores que um determinado parâmetro de aceitação, estabelecido pelo engenheiro de conhecimento. O parâmetro de aceitação utilizado neste trabalho é 0.6. O algoritmo de *Poda e Normalização* esta descrito a seguir [REA93]:

Para cada arco da rede fazer:

- Calcular o valor líquido dos acumuladores (ACMLIQ) pela fórmula:

$ACMLIQ = \text{acumulador de recompensas} - \text{acumulador de punições}$

Se $ACMLIQ \leq 0$

Então

remover o arco da rede

Se não

Se acumulador de punições do arco > 0

Então

computar o peso do arco como $ACMLIQ / MAXLIQ$

onde

$MAXLIQ = \text{maior } ACMLIQ \text{ da subrede da hipótese à qual o arco pertence}$

Se não

computar o peso do arco como:

$SQRT(\text{Paraceit}) + (1 - (SQRT(\text{Paraceit}))) * ACMLIQ / MAXLIQ$

onde

$\text{Paraceit} = \text{parâmetro de aceitação, definido pelo engenheiro de conhecimento}$

Se o peso do arco $<$ parâmetro de poda

então remover o arco da rede

- Remover todos os neurônios das camadas de entrada e combinatória que percam conectividade com os nós de hipótese.

O aprendizado incremental é implementado no MNC através do algoritmo de *Punição e Recompensa - versão Refinamento*, cujo objetivo é mimetizar a capacidade de aprendizado por experiência dos seres humanos [MAC91][REA93]. Este algoritmo também produz uma rede treinada não operante com acumuladores com valores entre $-n$ e $+n$, para “ n ” número de casos. O princípio das duas versões, arranque e refinamento, deste algoritmo é o mesmo: recompensar os ramos da rede que levam ao diagnóstico correto e punir os ramos da rede que levam a diagnósticos incorretos. Descreve-se abaixo, a versão de refinamento do algoritmo [REA93]:

Para cada exemplo da base de casos fazer:

- propagar os sinais de entrada até a camada de hipótese;
- para cada arco que alcance algum nodo de hipótese H, fazer:

Se o nodo de hipótese alcançado corresponde a um resultado correto,

Então, calcular $a = 1 - \text{ativação (H)}$,

- propagar retroativamente, a partir deste nó, até os nós de entrada, um acréscimo no valor do acumulador de recompensas, de acordo com a fórmula:

$$a * FE * AD * IE$$

onde:

FE = fluxo evidencial,

AD = ativação do neurônio de destino,

IE = importância do exemplo para o treinamento.

Se não, calcular $a = \text{ativação (H)}$,

- propagar retroativamente um acréscimo no valor do acumulador de punições deste nodo, até os nodos de entrada, de acordo com a fórmula:

$$FE * AD * IE$$

onde:

FE = fluxo evidencial,

AD = ativação do neurônio de destino,

IE = importância do exemplo para o treinamento.

Para transformar a rede treinada pelo algoritmo de *Punição e Recompensa - versão de Refinamento*, em uma rede operante, aplica-se o mesmo algoritmo de *Poda e Normalização*, anteriormente mencionado, com o objetivo de transformar os acumuladores de punição e recompensa em pesos de conexão e remover conexões de peso muito baixo.

Em modelos híbridos fortemente acoplados, o sistema deve garantir que qualquer alteração na estrutura de uma rede neural seja propagada ao formalismo simbólico de representação de conhecimento. O **HYCONES** utiliza o *fator de sensibilidade* para determinar os *achados-essenciais* e o *fator de especificidade* para determinar o *gatilho* de um frame diagnóstico, a partir do modelo neural MNC, para então, incorporá-los aos frames de diagnóstico.

O *fator de sensibilidade* mede a frequência com que um determinado achado (f) é identificado para um determinado diagnóstico (D). A fórmula para calcular a sensibilidade é mostrada abaixo [REA93][OWE90]:

Sensibilidade do achado f em relação ao diagnóstico D é determinado por:

$$\text{Sensibilidade} = \frac{\text{Número de casos onde um achado f está presente no diagnóstico D}}{\text{Número total de casos com diagnóstico D}}$$

Deve-se estabelecer um parâmetro de aceitação para que um achado possa ser considerado como essencial para um diagnóstico. Este parâmetro, pertencente ao intervalo [0,1], indica a frequência com que um achado deve aparecer nos casos de treinamento do mesmo diagnóstico, para ser considerado essencial.

A especificidade de um achado f , em relação a um diagnóstico D indica quão específico o achado é para o referido diagnóstico [REA93]. Calcula-se a especificidade de um achado em relação a um diagnóstico pela fórmula:

$$\text{Especificidade} = \frac{\text{Número de casos sem o achado } f \text{ com diagnósticos diferentes de } D}{\text{Número total de casos com diagnósticos diferentes de } D}$$

Dado que o *gatilho* de um diagnóstico é selecionado da sua lista de *achados-essenciais*, ele consistirá no mais específico dos achados de maior sensibilidade para o diagnóstico.

Em casos onde houver mais de um achado com a mesma especificidade, para um determinado diagnóstico, o **HYCONES** usa o fator de relevância para determinar o *gatilho*. Esta propriedade é definida, pelo especialista, para cada achado e determina quão significativo é um certo achado em relação aos demais.

Todavia, no modelo **SECOX-HI**, o mecanismo de inferência não atua sobre a parte simbólica de representação de conhecimento, alterações na estrutura das redes neurais não são propagadas as estruturas de dados relacionais, porém, mudanças nas estruturas de dados relacionais que correspondam a alguma alteração no conhecimento da base de conhecimento são transferidas às redes neurais pela alteração dos respectivos arquivos enviados às redes e pelo treinamento destas.

Como o modelo **SECOX-HI** é fracamente acoplado, não havendo integração entre as partes simbólica e conexionista, exceto pelo envio de arquivos, a manutenção da consistência e integridade da base de conhecimento é difícil. Alterações nas estruturas de dados relacionais implicam na geração de novos arquivos para as redes e novo treinamento destas, para incorporar as mudanças.

5 IMPLEMENTAÇÃO DO SISTEMA SECOX-HI

A proposta inicial para a realização deste trabalho foi usar o modelo conexionista híbrido **HYCONES**, descrito no item 2.9, que integra o formalismo de representação de conhecimento de frames ao modelo conexionista MNC, descrito no capítulo 2.

Por razões de limitação de hardware e por problemas de instalação do ambiente necessário à execução do **HYCONES** em estações de trabalho SUN, não foi possível a utilização dessa ferramenta. Optou-se então, pelo desenvolvimento de um modelo para sistema especialista híbrido, o **SECOX-HI**, que também utiliza o modelo conexionista MNC.

O modelo desenvolvido incorpora a representação simbólica do conhecimento, realiza a função da interface com usuário e a integração com o paradigma conexionista, o MNC.

5.1 O ambiente computacional

O modelo de sistema especialista híbrido **SECOX-HI**, utiliza dois ambientes computacionais para a sua execução. A parte simbólica foi implementada num equipamento IBM PC compatível, com processador Intel 80386, sob sistema operacional MSDOS 5.0, com um mínimo de 670 kbytes de memória RAM. O sistema é instalado em disco rígido. Foi utilizada a linguagem de programação CLIPPER, compilador versão 5.0, para implementar as estruturas de dados, as funções de manipulação da base de conhecimento e a interface do usuário.

O modelo conexionista MNC, foi implementado em linguagem de programação C, em máquina SUN, sob sistema operacional UNIX. Este modelo foi desenvolvido por Alex Guazelli, do Instituto de Informática da UFRGS, em um trabalho anterior.

5 2 Implementação da Base de Conhecimento

A base de conhecimento híbrida é definida a partir das estruturas relacionais de evidências e diagnósticos.

A classe *evidências* é descrita por um conjunto de três estruturas de dados. A estrutura de dados **EVS** armazena a descrição das evidências, seu tipo (discreta ou nebulosa), sua notação e o seu identificador. É composta dos seguintes campos de dados:

EVS_COD = identificador de uma evidência

EVS_NM = descrição de evidência

EVS_TIPO = tipo da evidência

EVS_NOT = notação da evidência

A estrutura de dados **EVSD** armazena os atributos de uma evidência do tipo discreta, é composta pelos seguintes campo:

EVSD_C = identificador de uma evidência

EVSD_CC = identificador de um atributo de evidência

EVSD_AT = descrição do atributo

Para exemplificar, considera-se a evidência *nível do reservatório de Passo Real*. Seu tipo é *discreto*, a ela estão associados as possíveis faixas de nível do reservatório consideradas no domínio da aplicação. Os atributos *maior que 0.50 m, e entre 0.40 e 0.50 m*, por exemplo, estão associados a evidência *nível do reservatório de Passo Real*, na forma de instâncias da estrutura de dados **EVSD**.

A estrutura de dados **EVSF** armazena os atributos de uma evidência do tipo nebulosa, é composta pelos seguintes campos:

EVSF_C = identificador de uma evidência

EVSF_CC = identificador de um atributo de evidência

EVSF_AT = descrição do atributo

TZ_X1 = primeiro vértice do trapezóide que descreve a função de pertinência do atributo nebuloso

TZ_X2 = segundo vértice do trapezóide que descreve a função de pertinência do atributo nebuloso

TZ_X3 = terceiro vértice do trapezóide que descreve a função de pertinência do atributo nebuloso

TZ_X4 = quarto vértice do trapezóide que descreve a função de pertinência do atributo nebuloso

O identificador *atributo de evidência* identifica um determinado atributo associado a uma evidência. Considera-se que o *nível do reservatório de Passo Real* possua como identificador a expressão *E1*, o atributo *maior que 0.50 m* pode, por exemplo, ter como identificador a expressão *D1*, portanto a relação da evidência *E1* (*nível do reservatório de Passo Real*) com o atributo *D1* (*maior que 0.50 m*) é identificada pela composição de ambos identificadores, neste caso, o identificador composto *E1D1*. Os campos de identificadores das estruturas de dados relacionais constituem as chaves primárias destas estruturas. Evidências do tipo discreta possuem identificadores iniciando pela letra *D*, evidências do tipo nebulosa possuem identificadores iniciando pela letra *F*. A geração e controle dos identificadores é feita internamente pelo sistema.

A classe *diagnósticos* é descrita pela estrutura de dados **DIAG**. Esta estrutura armazena a descrição dos diagnósticos e seus respectivos identificadores. É composta dos seguintes campos de dados:

DIAG_D = descrição do diagnóstico

DIAG_C = identificador do diagnóstico

A associação de evidências a um diagnóstico é representada por uma estrutura de dados identificada pelo campo *identificador do diagnóstico* da estrutura **DIAG**. Esta estrutura é composta por dois campos de dados, conforme descrito abaixo:

EV_G = identificador composto de evidência/atributo

EV_W = peso da evidência para a determinação do diagnóstico

Esta estrutura é gerada no momento da associação de evidências a diagnósticos, seu nome é composto pelo identificador do diagnóstico ao qual se refere as evidências. Por exemplo, se o diagnóstico regime de **emergência** possui como identificador a expressão *D01*, no momento em que for realizada a associação de evidências ao regime de **emergência**, será gerada a estrutura de dados **D01**, para armazenar as evidências selecionadas.

A estrutura de dados **DAT**, é utilizada para armazenar os casos de treinamento inseridos no sistema. Cada caso é definido pelos valores associados aos campos da estrutura. Os campos de dados da estrutura **DAT** correspondem as evidências inseridas no sistema, isto é, para cada instância da estrutura de dados **EVS** existe um campo de dados correspondente na estrutura da dados **DAT**. A estrutura de dados **DAT** é composta pelos seguinte campos:

DT_NIVEL = nível do reservatório

DT_AF = afluência em PBV

DT_VAZ = variação da vazão

DT_PR = precipitação no reservatório

DT_PH1 = precipitação na bacia hidrográfica, dia atual

DT_PH2 = precipitação na bacia hidrográfica, dia anterior

DT_PH3 = precipitação na bacia hidrográfica, três dias atrás

DT_TUB = vazão turbinada

DT_VET = vazão vertida

DT_REG = regime de operação

DT_DAT = data da ocorrência

Adicionalmente a estas estruturas de dados, existem duas outras estruturas responsáveis pela comunicação com o componente conexionista do sistema. A estrutura de dados **BOARD**, armazena um conjunto de evidências selecionadas durante uma operação de consulta, para posterior envio ao modelo conexionista MNC. Esta estrutura possui os seguintes campos:

BD_EV = identificador composto de evidência/atributo
 BD_W = peso da evidência

A estrutura de dados **BASE**, cumpre a mesma função da estrutura anterior, porém em relação aos casos armazenados na base de casos, cada ocorrência da bases de casos é transferida a estrutura de dados **BASE**, para posterior envio ao modelo conexionista MNC. A estrutura de dados **BASE** possui os seguintes campos:

BASE_EV = identificador composto de evidência/atributo
 BASE_W = peso da evidência

Além dessas existem outras estruturas de dados que armazenam informações relativas ao sistema. As estruturas, não relacionais, **FINDS.CHD** e **CONFIG.CHD**. Estas estruturas, ao contrário das anteriores, são diretamente acessadas pelo modelo neural MNC, portanto ficam residentes na estação de trabalho SUN.

O arquivo de dados **FINDS.CHD** contém todos os elementos da classe *evidências* com um valor associado a cada um. Este valor, no intervalo de [0,1] é o fator de relevância de cada evidência, que determina a importância da cada uma na operação do sistema. O fator de relevância das evidências foi estabelecido pelo especialista Jairo dos Santos, juntamente com o engenheiro de conhecimento.

O arquivo de dados **CONFIG.CHD** armazena informações referentes a configuração do sistema. As informações definidas por esse arquivo são:

order: ordem de combinação dos nodos de entrada da rede neural, o **SECOX-HI** trabalha com ordem 3;

number_of_hypotheses: número de elementos da classe *diagnóstico*, é 3 para o trabalho aqui descrito;

input_neurons_load: número de nodos de entrada da rede neural, corresponde aos elementos da classe *evidências*, recebe o valor 36;

acceptance_threshold: parâmetro de aceitação, no qual um caminho de saída das redes neurais é considerado como possível solução do problema proposto, o **SECOX_HI** utiliza 0.3 como limite de aceitação;

prunning_threshold: parâmetro de poda, arcos da rede neural com valores inferiores a esse limite são desativados, o **SECOX-HI** utiliza 0.6 como limite de poda;

number_of_cases_learn: número de casos de aprendizagem, inseridos na base de casos. Foi definido um valor máximo de casos de aprendizagem no desenvolvimento do trabalho, igual a 69. Consultar o capítulo 6 para informações sobre a base de casos;

number_of_cases_test: número de casos existentes na base de testes, igual a 30. O capítulo 7 refere-se a construção da base de testes;

number_of_refinements: número de refinamentos das redes neurais, durante o processo de aprendizagem, foi estabelecido o valor 1.

Esses valores foram definidos pelo engenheiro de conhecimento.

5.3 Operação do sistema SECOX-HI

A operação do modelo para SE híbrido, **SECOX-HI**, pode ser dividida em três etapas, que correspondem às funções implementadas pelo modelo. Inicialmente introduz-se o conhecimento declarativo no sistema, que compreende os diagnósticos, que são as classificações do domínio, as evidências, que são a porção do conhecimento que suportam as conclusões apontadas pelo sistema e as associações entre evidências e diagnósticos.

Numa segunda fase, introduz-se os casos na base de casos. A terceira etapa consiste no módulo de consulta do sistema, onde um conjunto de evidências é selecionado para consulta ao motor de inferência.

5.3.1 Manutenção do conhecimento declarativo

O modelo **SECOX-HI** foi aplicado no problema de detecção de regime de operação no sistema hidroelétrico JACUÍ. Definiu-se o escopo da aplicação para aquelas situações mais críticas, onde as falhas podem causar danos consideráveis às usinas geradoras e ao meio ambiente.

A primeira tarefa para a operação do modelo consiste na inserção de evidências e seus respectivos atributos. Deve-se considerar que o modelo opera com dois tipos de classificação para evidências, *nebulosa* e *discretas*. Quando uma evidência for nebulosa, deve-se informar as coordenadas dos pontos da função de pertinência, no caso aqui descrito, os pontos correspondem aos vértices dos trapezóides, descritos no item 4.1.2. A figura 28 exemplifica uma operação de inserção de *evidências*.



Figura 28 Manutenção de evidências

No exemplo da figura 28, foi inserida a evidência *vazão turbinada*, com os atributos *alta*, *média* e *baixa* e seus respectivos pontos que definem os vértices dos

trapezóides. A próxima operação a ser realizada é a inserção dos elementos da classe diagnóstico, pelo módulo de manutenção de diagnósticos.

A opção "Associar" deste módulo realiza a associação das evidências ao diagnóstico selecionado. Primeiramente seleciona-se o diagnóstico desejado, depois, na moldura de evidências, seleciona-se as evidências que contribuem para a ocorrência do diagnóstico, atribuindo-se a estas um valor de importância, no intervalo [0,1]. A figura 29 ilustra uma operação no módulo de manutenção de diagnósticos.

OPERA
SECO 8 - H I

Consulta Evidencias Diagnosticos Banco de Casos Configurar Sair

PESO: 9.5

Inserir
Editar
Excluir
Associar
Sair

DIAGNOSTICOS

REGIME DE EMERGENCIA
REGIME DE UERTIMENTO
REGIME DE ALERTA

EVIDENCIAS TIPO

NIVEL RESERBUATORIO PASSO REAL 10
AFLUENCIA PEU PARA UERTIMENTO 10
AFLUENCIA PEU PARA ALERTA 10
AFLUENCIA PEU PARA EMERGENCIA 10
VARIACAO DA VAZAO 10
PRECIPITACAO PASSO REAL 10

ATRIBUTO	PT X1	PT X2	PT X3	PT X4
ALTA	35	45	500	500
MEDIA	15	25	35	45
BAIXA	-100	-100	15	25
	:	:	:	:
	:	:	:	:

<Esc>Termina <PF3>Executa

Figura 29 Manutenção de diagnósticos

A figura 29 ilustra a associação da evidência *variação de vazão alta*, com peso de 9.5 ao diagnóstico regime de **emergência**. Dessa forma, o sistema permite a inclusão de combinações de evidências a um respectivo diagnóstico.

5.3.2 Manutenção da base de casos

O módulo do sistema responsável pela manutenção da base de casos realiza a inserção e exclusão de casos no sistema, também executa a geração dos arquivos a serem lidos pelas redes neurais.

A inserção de um caso, ou ocorrência, deve ser executada após a inserção dos diagnósticos. Pois, cada ocorrência inserida deve ser associada a um diagnóstico, e o sistema só permite a associação de casos a diagnósticos conhecidos (previamente cadastrados).

As evidências, já inseridas no modelo, são assumidas como campos de uma estrutura, cujos registros devem ser preenchidos com os respectivos valores de cada campo, formando assim uma ocorrência.

A figura 30 ilustra o cadastramento de uma ocorrência para regime de **vertimento**. Os campos da tela, para a edição dos valores, correspondem as evidências inseridas no sistema.

O módulo de manutenção da base de casos também pode ser utilizado para a inserção de grafos de conhecimento, na forma de ocorrências e seu posterior envio às redes neurais.



Figura 30 Inclusão de ocorrências

5.3.3 Módulo de consulta

Uma vez montada a base de conhecimento e inseridos os casos de treinamento para as redes neurais, pode-se executar uma operação de consulta. Devido a não integração total entre as partes simbólica e conexionista, é permitido que várias consultas sejam armazenadas para posterior execução.

Numa operação de consulta, seleciona-se as evidências e seus respectivos atributos. O conjunto de evidências selecionadas é inserido numa estrutura de dados, permitindo-se que nova consulta seja realizada ou que as consultas armazenadas sejam executadas.

Para executar uma consulta seleciona-se a opção "Executar" do módulo de "Consulta". Esta operação realiza a conversão do conjunto de evidências selecionadas para uma notação, na forma de nodos de entrada, compreensível pelas redes neurais. O resultado desta operação é um arquivo com valores entre [0,1], para ser enviado às redes neurais. A figura 31 mostra uma operação de consulta no modelo SECOX-HI.



Figura 31 Operação de consulta

A figura 31 demonstra a seleção da evidência *nível do reservatório Passo Real entre -1.27, 0 metros* numa operação de consulta. Depois de selecionada todas as evidências desejadas, pode-se entrar na opção "Executar" do menu de "Consulta", para realizar uma consulta ao sistema.

Uma vez apresentado um conjunto de evidências as redes neurais, estas passam a apresentar sinais de saída referentes aos caminhos que levam as hipóteses diagnósticas. As redes neurais, na sua conclusão, exibem os casos apresentados para treinamento e os caminhos com seus respectivos pesos de saída, e apontam como solução do problema o diagnóstico cujo caminho possua o maior sinal de saída.

6 BASE DE CASOS

A utilização de uma base de casos pelo mecanismo de inferência do SE tem o propósito de prover o SE de capacidade de explicitação automática de conhecimento e de aprendizado incremental, por casos de treinamento das redes neurais.

Depois de determinados todos os elementos das classes evidências e diagnóstico, foi realizada uma pesquisa para levantar ocorrências históricas pertinentes ao domínio da aplicação, ou seja, registros de cheias ocorridas ou situações onde foram realizados vertimentos por abertura de comportas.

A pesquisa procurou levantar registros de períodos de tempo diferentes (anos), e de ocorrências de todos os diferentes regimes de operação considerados no sistema. Ressalta-se que não houve registros coletados sobre situações de regime de **emergência**, visto que nunca foi registrada tal ocorrência.

As situações mais críticas verificadas foram de regime de **vertimento** com altos valores para defluência vertida e nível do reservatório. Os casos de treinamento e testes referentes a regime de **emergência** foram estipulados, pelo engenheiro de conhecimento, tendo como base os grafos de conhecimento relativos à regime de **emergência**.

A montagem da base de casos foi feita em três etapas. Inicialmente procurou-se nos gráficos demonstrativos sobre as defluências os períodos de maiores picos, indicados em mes/ano. São os períodos de julho de 1987, setembro de 1989, setembro de 1990, maio de 1992, junho de 1992 e julho de 1992.

Após essa etapa, foram selecionadas as planilhas de "*Dados Hidrológicos Mensais do RPRE*" referentes aos períodos considerados (ver anexo D). Essas planilhas possuem as informações diárias relativas a precipitações, aos níveis do reservatório, ao armazenamento, à defluência, à afluência e à energia gerada.

Com base nas planilhas de "*Dados Hidrológicos Mensais do RPRE*" foram selecionados, pelo engenheiro de conhecimento, os dias que apresentavam maiores volumes de defluência, ou precipitações mais elevadas. Situações características de uma cheia. A próxima etapa consistiu no levantamento dos dias selecionados na etapa anterior, nas planilhas de "*Dados de Produção e Hidrológicos*".

Esta planilha, preenchida diariamente no COS, apresenta as informações em intervalos horários. Por exemplo, indica os níveis horários do reservatório, a defluência e afluência a cada hora, o que permite calcular a variação da vazão. A planilha de "*Dados de Produção e Hidrológicos*" informa, também, as precipitações em vários pontos da bacia hidrográfica de Passo Real, além de outras informações relacionadas à geração de energia (ver anexo E).

De posse das planilhas citadas acima, foi montada uma terceira planilha, para o registro dos dados obtidos. Algumas planilhas da base de casos estão no anexo F. Ao total foram selecionadas 149 ocorrências, sendo 112 referentes à regime de **vertimento**, 17 à regime de **alerta** e 20 à regime **normal**. As ocorrências referentes ao regime **normal** não foram inseridas no sistema, pois este regime não foi considerado na classe *diagnósticos* no sistema. Em relação a considerável diferença no número de ocorrências do regime de **vertimento** em relação ao **alerta**, explica-se pelo fato de que deu-se prioridade aquelas ocorrências características à situação de cheias, que apresentavam vertimento e, portanto, pertencem à operação em regime de **vertimento**.

A figura 32 mostra um exemplo da planilha para o cadastramento de ocorrências:

DATA		05/07/92	06/07/92
NÍVEL RPRE (M)		- 0.98	- 0.88
AFLUENCIA PBV (M3/S)		830	494
V. VAZÃO (M3/S/H)		31	84
PRECP RPRE (MM/DIA)		18.8	0
PRECP BACIA HIDRO D1 (MM/DIA)	MAIA FILHO	14.8	0
	ITAUBA	19	0
	ERNESTINA	35	0
	PBV	37	0
	ESPUMOSO	0	0
	CAPIGUI	60	0
PRECP BACIA HIDRO D2 (MM/DIA)	MAIA FILHO	26.4	14.8
	ITAUBA	30.1	19
	ERNESTINA	58	35
	PBV	18.2	37
	ESPUMOSO	0	0
	CAPIGUI	41	60.2
PRECP BACIA HIDRO D3 (MM/DIA)	MAIA FILHO	0	26.4
	ITAUBA	0	30.1
	ERNESTINA	0	58
	PBV	0	18.2
	ESPUMOSO	0	0
	CAPIGUI	0	41
VAZÃO TURBINADA (M3/S)		335.3	335.6
VAZÃO VERTIDA (M3/S)		258.0	0
REGIME		vertimento	vertimento

Figura 32 Planilha para a montagem da base de casos

7 BASE DE TESTES

Paralelamente à base de casos foi montada uma base de testes, para efeito de validação do sistema. A base de testes é um subconjunto da base de casos, isto é, as ocorrências selecionadas para validar as respostas do sistema foram extraídas aleatoriamente da base de casos. Uma ocorrência selecionada para a base de testes não participa da base de casos. Não existem, portanto, ocorrências que pertençam a ambas as bases simultaneamente.

A base de testes é composta de 30 ocorrências, sendo 7 relativas à regime de **alerta**, 6 relativas à regime de **emergência** e 17 relativas à regime de **vertimento**. Essas quantidades foram estipuladas aleatoriamente, conforme o número de ocorrências de cada regime de operação na base de casos.

8 VALIDAÇÃO

A fim de verificar os objetivos propostos, o modelo para SE híbrido **SECOX-HI**, foi aplicado ao problema decisório de detecção de regime de operação dos reservatórios das usinas hidroelétricas, no sistema hidroelétrico Jacuí, na CEEE.

Para validar o desempenho do modelo utilizou-se a base de casos e a base de testes, descritas nos capítulos 6 e 7, respectivamente.

Foram construídas três versões da base de casos, com o intuito de treinar as redes neurais e verificar sua capacidade de aquisição automática de conhecimento por casos de treinamento e sua capacidade de aprendizagem indutiva, por refinamento das redes treinadas. Optou-se pela utilização de três versões da base de casos para verificar o desempenho do sistema pelo treinamento das redes neurais através de exemplos extraídos de diferentes fontes, particularmente, entre os exemplos extraídos dos casos reais ocorridos e aqueles determinados pelos grafos de conhecimento colhidos do especialista.

A primeira versão da base de casos, **B1**, constitui-se dos casos extraídos das planilhas de *“Dados de Produção e Hidrológicos”*. Esta versão possui 60 ocorrências, sendo 50 referentes ao regime de **vertimento** e 10 referentes ao regime de **alerta**.

A segunda versão da base de casos, **B2**, constitui-se do conhecimento extraído dos especialistas, de acordo com a metodologia dos grafos de conhecimento, descrita por [LEA90]. Os grafos de conhecimento foram traduzidos para a forma de ocorrências e inseridos na base de casos. Esta versão da base de casos possui 69 ocorrências, sendo 23 referentes ao regime de **emergência**, 20 referentes ao regime de **alerta** e 26 referentes ao regime de **vertimento**.

A terceira versão da base de casos, **B3**, é uma base híbrida, formada por ocorrências das versões **B1** e **B2**. Possui 60 ocorrências, sendo 30 referentes ao regime de **vertimento**, 18 referentes ao regime de **alerta** e 12 ao regime de **emergência**.

Para validar as três versões do sistema foi utilizada a base de testes, cujas ocorrências foram selecionadas aleatoriamente entre os casos levantados na planilha de “*Dados de Produção e Hidrológicos*” e dos grafos de conhecimento colhidos dos especialistas. A base de testes possui 30 ocorrências, sendo 7 referentes ao regime **alerta**, 6 referentes ao regime de **emergência** e 17 ao regime de **vertimento**, conforme citado no capítulo 7.

A tabela II, a seguir, exhibe o desempenho das três versões do sistema.

Tabela II Desempenho das três versões do SECOX-HI

	Versão B1		Versão B2		Versão B3	
	número	%	número	%	número	%
Acertos	29	96.7	22	73.4	27	90
Erros ou não concluiu	1	3.3	8	26.6	3	10
Total	30	100	30	100	30	100

A versão **B1**, baseada nos casos colhidos das planilhas “*Dados de Produção e Hidrológicos*” concluiu corretamente 29 (96.6%) dos 30 diagnósticos da base de testes. Fez apenas 1 (3.3%) erro na conclusão diagnóstica.

A versão **B2**, formada pelos grafos de conhecimento dos especialistas, foi a que apresentou pior desempenho, concluiu corretamente 22 (73.4%) dos 30 diagnósticos e errou 8 (26.6%) conclusões.

A versão híbrida **B3**, formada por casos extraídos das versões **B1** e **B2**, concluiu corretamente 27 (90%) dos diagnósticos e errou 3 (10%) dos casos apresentados.

Pela tabela II, pode-se constatar o bom desempenho do modelo em relação as suas respostas. Devido ao baixo número de erros da versão **B1** da base de

casos, 3.3%, verifica-se a boa capacidade para aquisição de conhecimento via casos de treinamento, e a importância dessa solução para a tarefa de aquisição de conhecimento em sistemas especialistas.

Embora a versão **B2** da base de casos, formada pelos grafos de conhecimento colhidos dos especialistas tenha apresentado o menor desempenho, uma margem de erro de 26.6%, ressalta-se que existe a possibilidade de refinar os grafos de conhecimento, verificando-se os erros apresentados e submetendo-os a novas avaliações com o especialista. A metodologia de construção de grafos de conhecimento demonstrou gerar porções corretas do conhecimento do domínio da aplicação, constituindo uma ferramenta eficiente para a aquisição de conhecimento de especialistas, em problemas classificatórios.

Aplicou-se o teste qui-quadrado (X^2), para comparar o desempenho das versões **B1**, **B2** e **B3**, conforme mostra a tabela abaixo.

Tabela III Tabela de contingência comparativa das três versões do SECOX-HI

Versão	Diagn. Corretos	Diagn. Errados ou não concluiu	Total
B1	29	1	30
B2	22	8	30
B3	27	3	30

$\chi^2 = 7.49$, 2 graus de liberdade, $p=0.02351775$ ($p<0.050$)

Pelos resultados da tabela III pode-se concluir, a um nível de significância de 5%, que não há homogeneidade no desempenho das três versões do sistema, isto é, houve diferença estatística entre o desempenho das três versões. Com o objetivo de comparar individualmente a versão **B1** com as demais, aplicou-se

novamente o teste qui-quadrado. A tabela com os valores X^2 obtidos está relacionada abaixo.

Tabela IV Valores X^2 obtidos na comparação entre as versões B1 e B2, B1 e B3

Versão	χ^2	p (unilateral)
B1 x B2	4,7 (*)	0.0128454 (**)
B1 x B3	0,27 (*)	0.3059768 (**)

(*) Com correção de Yates para as frequências reais

(**) Pelo teste exato de Fisher

Pelos resultados obtidos com o teste qui-quadrado pode-se verificar que a versão **B1** da base de conhecimento, treinada automaticamente através do banco de casos, obteve melhor desempenho que a versão **B2**, treinada a partir dos grafos de conhecimento colhidos dos especialistas. Não foram detectadas diferenças estatisticamente significativas, entre as versões **B1** e **B3**. Isto significa que a base de conhecimento treinada automaticamente a partir da base de casos (**B1**) teve um desempenho semelhante a base de conhecimento treinada através da base híbrida (**B2**).

A validação do **SECOX-HI** visa, também, verificar a formação de *germes de conhecimento* gerados pelas redes neurais criadas a partir da base de casos. *Germes de conhecimento* são caminhos mínimos que conduzem aos diagnósticos.

Para tanto, utilizou-se os conceitos de *gatilho*, *achados-essenciais*, *achados-complementares* e *achados-de-negação*, descritos em [LEA90] e [REA93] e citados no item 4.2.

De forma análoga ao **HYCONES**, o modelo utiliza o *fator de sensibilidade* para determinar os *achados-essenciais* e o *fator de especificidade* para determinar o *gatilho* de uma hipótese diagnóstica. As fórmulas para calcular os fatores de especificidade e sensibilidade estão descritas no item 4.4.

Foi estabelecido um parâmetro de aceitação para que um achado fosse considerado como essencial para um diagnóstico. O parâmetro de aceitação utilizado neste trabalho foi 0.75, conforme utilizado no sistema **HYCONES**.

Após determinar-se os *achados-essenciais*, identifica-se o *gatilho* para a hipótese diagnóstica. O *gatilho* indica qual, dentre os *achados-essenciais*, é o mais importante no processo de identificação do diagnóstico. É usado o *fator de especificidade* para determinar a importância dos achados para o diagnóstico.

A versão **B1** da base de casos foi utilizada para determinar os *achados-essenciais* e o *gatilho* para os objetos da classe diagnóstico do problema considerado neste trabalho. Esta versão da base de casos foi extraída das planilhas de ocorrências do COS, portanto não apresenta ocorrências para o diagnóstico regime de **emergência**. A operação dos reservatórios do sistema hidroelétrico Jacuí, até hoje, nunca atingiu regime de **emergência**.

Portanto, os cálculos de sensibilidade e especificidade foram realizados para os diagnósticos regime de **vertimento** e **alerta**.

A base de casos, versão **B1**, possui 60 ocorrências, sendo 50 referentes ao regime de **vertimento** e 10 ao regime de **alerta**. Justifica-se o menor número de casos para regime de **alerta** devido ao fato de que, no levantamento dos dados, foi dada prioridade às ocorrências mais críticas, que apresentavam maiores afluências, precipitações e níveis de reservatório mais elevados, característicos de situação de cheias e, portanto, relativos ao regime de **vertimento**.

Para o regime de **alerta** não houve evidências com *fator de sensibilidade* maior que 0.75. As evidências com maior *fator de sensibilidade* apresentaram valor 0.60. Portanto, não foi possível determinar-se os *achados-essenciais* e o *gatilho* para

esta hipótese diagnóstica. Esse fato ocorreu, provavelmente, devido ao número reduzido de ocorrências na base de casos, para regime de **alerta**, pelas razões citadas no parágrafo anterior.

Para o regime de **vertimento**, três evidências apresentaram *fator de sensibilidade* superior a 0.75. As evidências com seus respectivos valores de sensibilidade (S) são:

- * nível do reservatório RPRE entre [-1.27, 0] metros. - S=0.80
- * afluência PBV superior a 500 m³/s. - S=0.80
- * vazão turbinada alta, superior a 200 m³/s. - S=1.00

Foi realizado o cálculo de especificidade para determinar qual das três evidências, acima citadas, corresponde ao *gatilho* para a hipótese diagnóstica regime de **vertimento**. As evidências e seus respectivos valores de especificidade (E) estão listados abaixo:

- * nível do reservatório RPRE entre [-1.27, 0] metros. - E=1.00
- * afluência PBV superior a 500 m³/s. - E=0.50
- * vazão turbinada alta, superior a 200 m³/s. - E=0.70

A partir dos cálculos de sensibilidade e especificidade concluiu-se que as redes neurais formaram corretamente *germes de conhecimento*. A evidência “*nível do reservatório RPRE entre [-1.27, 0] metros*” foi apontada pelo especialista como a de maior relevância para diagnóstico regime de **vertimento**. Tendo, o especialista, desenhado um caminho direto entre o nodo de entrada que representa esta evidência e o nodo da saída da hipótese regime de **vertimento**, quando da confecção dos grafos de conhecimento.

As demais evidências foram corretamente consideradas pelas redes neurais. A evidência “*vazão turbinada alta*”, é uma evidência muito presente em regime de **vertimento**, o que justifica o valor 1.00 no cálculo de sensibilidade, porém é de ocorrência muito alta em regime de **alerta**, e obrigatória em regime de **emergência**, o que justifica o valor 0.70 no cálculo de especificidade. Embora o

regime de **emergência** não tenha sido considerado nos cálculos de sensibilidade e especificidade, a informação fornecida pelo especialista através da confecção dos grafos de conhecimento contribuiu para verificar-se a correção dos cálculos, que apontam a evidência "*vazão turbinada alta*" com o maior valor de sensibilidade, mas valor menor para a especificidade.

Avaliação semelhante pode ser feita à evidência "*afluência PBV superior a 500 m³/s*". Examinado-se os gráficos da função de pertinência das variáveis nebulosas, no item 4.1.2, pode-se verificar que o valor 500 é considerado uma taxa de afluência alta tanto para regime de **alerta** como para regime de **vertimento**. Portanto, presente em ambas situações, o que justifica o valor 0.50 para o fator de especificidade dessa evidência.

Para constatar a correção dos valores obtidos no cálculo de especificidade e sensibilidade, verificou-se as redes neurais que apresentaram maiores valores de saída, na validação do sistema pela base de casos versão **B1**. O *frame* de identificação do diagnóstico regime de **vertimento** está representado abaixo, juntamente com os grafos de conhecimentos colhidos dos especialistas que apresentam as evidências relacionadas acima e as redes neurais que apresentaram maiores sinais de saída para regime de **vertimento**.

Considerando-se:

E5 - nível do reservatório RPRE entre [-1.27, 0] metros

E12 - afluência PBV superior a 500 m³/s

E31 - vazão turbinada alta, superior a 200 m³/s

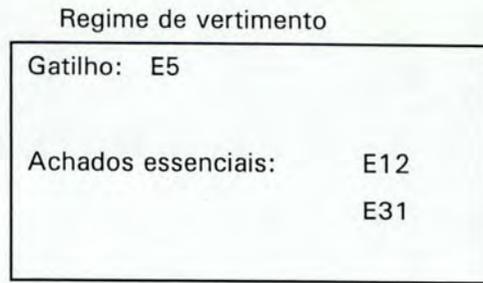


Figura 33 Frame para regime de vertimento



Figura 34 Redes Neurais com maiores sinais de saída

Considerando-se:

E6 - nível do reservatório RPRE entre [-1.40,-1.27] metros

E1 - variação alta da vazão

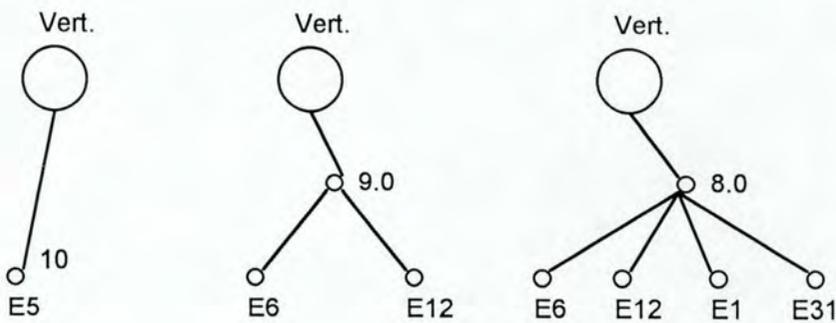


Figura 35 Grafos de Conhecimento colhidos do especialista para regime de vertimento

Os resultados obtidos mostram que o mecanismo de inferência, baseado no MNC, pode apresentar um ótimo desempenho, dependendo dos casos armazenados na base de casos. Os casos de erros do sistema resultaram, na maioria das vezes, da insuficiência de casos para treinamento, ou problemas de modelagem e interpretação na confecção dos grafos de conhecimento, caso dos regime de **emergência e alerta**.

Em relação à representação do conhecimento, a divisão em *classes de evidências* e *diagnósticos* demonstrou ser uma abordagem eficiente em problemas do tipo classificatório. Ela permitiu a representação eficiente do conhecimento do domínio da aplicação, bem como a manutenção desse conhecimento.

Por último, pode-se constatar a eficiência da utilização das abordagens simbólica e conexionista integradas. Enquanto a abordagem simbólica permitiu uma representação do conhecimento mais fácil e acessível, a parte conexionista permitiu uma implementação mais fácil para o aprendizado e aquisição automática de conhecimento, além de ter realizado a inferência de maneira eficiente numa situação que apresenta explosão combinatória, como é o caso do problema da detecção de regime de operação, considerado neste trabalho.

9 CONSIDERAÇÕES FINAIS

Este capítulo apresenta uma síntese do trabalho realizado e uma discussão sobre as limitações do modelo computacional desenvolvido, são relacionadas algumas contribuições do trabalho e alguns comentários sobre a utilização de SEs nas organizações, especificamente na CEEE.

O trabalho desenvolvido pretende, de uma forma mais ampla, validar um SE como ferramenta de apoio à decisão, incorporando ao SE a capacidade de pesquisa e consulta a um banco de casos referente ao problema decisório, de modo que o SE possa, no seu processo de inferência, “lembrar” de situações anteriores e usar este conhecimento para avaliar e resolver novos problemas, de uma maneira similar ao comportamento humano.

Para tanto, foi feito um estudo sobre o estado atual no desenvolvimento de SE, sobre técnicas de aquisição de conhecimento, representação de conhecimento e inferência. Foi possível verificar a existência de métodos e propostas de solução para os problemas relacionados ao desenvolvimento de SE, e de sistemas de IA em geral. Entre estes, destacam-se o problema de aquisição de conhecimento, considerado o gargalo no desenvolvimento de SE, o problema de aprendizagem de máquina e a procura de métodos cada vez mais eficientes de busca.

A abordagem simbólica, no desenvolvimento de SE, caracteriza-se pelo uso de técnicas como *regras de produção*, *redes semânticas*, *frames*, entre outras, para a representação do conhecimento. A abordagem conexionista, inspirada nas estruturas do cérebro humano, utiliza *redes neurais* para a representação do conhecimento.

Ambos os paradigmas oferecem soluções para os problemas relacionados ao desenvolvimento de SE. A integração destes paradigmas permite que se utilize as vantagens de cada um. A abordagem conexionista oferece soluções eficientes para o aprendizado de máquina, porém dificulta a manutenção e compreensão do conhecimento representado. A abordagem simbólica permite uma representação mais flexível e compreensível do conhecimento.

Sistemas especialistas de arquitetura híbrida apresentam soluções eficientes para os problemas relacionados ao desenvolvimento de SE, integrando o processamento simbólico, lógica nebulosa, abordagem conexionista e algoritmos genéticos.

O modelo computacional desenvolvido neste trabalho foi inspirado no modelo para SE conexionista híbrido **HYCONES** que, para a representação do conhecimento, utiliza o mecanismo de frames integrado ao modelo conexionista MNC. O **HYCONES** realiza o aprendizado indutivo através do algoritmo de treinamento das redes neurais do MNC, e o aprendizado dedutivo por uma estratégia de reestruturação e treinamento das redes neurais [REA93]. A validação do **HYCONES** no diagnóstico de cardiopatias congênitas constatou sua eficiência.

O modelo computacional **SECOX-HI** incorporou o aprendizado indutivo realizado pelo MNC. A validação do **SECOX-HI**, no problema de detecção de regime de operação no sistema hidroelétrico Jacuí demonstrou o bom desempenho do modelo.

Os resultados obtidos nas validações do sistemas acima citados, **HYCONES** e **SECOX-HY**, permitem constatar a aplicabilidade e eficiência da técnica de SE híbridos no suporte a decisões, relacionadas a problemas classificatórios.

Apesar do bom desempenho, a validação do **SECOX-HI** apontou algumas restrições do modelo. A principal, talvez seja o problema da explosão combinatória. Para a automação do conhecimento, o MNC emprega um algoritmo de criação da rede neural que, inicialmente, gera combinações de todos os achados do domínio para cada diagnóstico, sem executar uma seleção prévia dos achados, a fim de agrupar apenas os mais relevantes para os diagnósticos. Este método exaustivo de agrupamento de achados em nodos intermediários do MNC gera o problema da explosão combinatória que, por sua vez, torna crítica a questão de recursos de hardware, principalmente no que se refere à alocação de memória principal e ao tempo de processamento.

Uma segunda limitação do modelo é o seu comprometimento com a aplicação para qual foi projetado, em relação às estruturas do banco de casos. A estrutura de dados do banco de casos foi desenvolvida para armazenar dados referentes a uma aplicação específica, portanto, foi concebida de acordo com os tipos

de dados desta aplicação. Para uma utilização genérica, em outros domínios, faz-se necessário a utilização de um banco de casos com estrutura mais flexível. Uma solução proposta, seria a utilização de um gerenciador de banco de dados integrado ao modelo.

Outra limitação do modelo refere-se ao fato deste ser classificado como fracamente acoplado, em relação à integração entre abordagem simbólica e conexionista. Esse fato torna muito complexa a manutenção da integridade do conhecimento armazenado na base de conhecimento e a comunicação entre as duas partes do modelo. A necessidade de transporte de arquivos, de uma plataforma de hardware para outra, praticamente inviabiliza o uso do modelo em situações reais. Novamente, faz-se necessário contornar o problema da explosão combinatória para portar o MNC para máquinas menores. Da mesma forma, seria interessante que o modelo conexionista pudesse fazer operações de acesso à disco, ao invés de manter o conhecimento integralmente em memória principal.

Este trabalho se propôs a aplicar e validar uma técnica para o suporte à decisão, a técnica de SE capaz de pesquisar uma banco de casos no processo de inferência, portanto, não foi dada prioridade ao desenvolvimento do sistema propriamente dito. Por essa razão a tarefa de explanação do SECOX-HI é limitada apenas ao arquivo de saída gerado pelo MNC, constituindo-se de uma forma de explanação pouco amigável e pouco flexível, porém, suficiente para a análise dos resultados do sistema. Pela mesma razão que não foi desenvolvida uma interface de explanação mais amigável e flexível, o sistema não incorpora tarefas de auxílio como telas explicativas das sua tarefas.

A validação do modelo demonstrou a eficiência da aquisição automática de conhecimento, por casos de treinamento. A versão do sistema constituída pela base de conhecimento gerada pelos registros de ocorrências históricas demonstrou a capacidade de aprendizagem e geração de germes de conhecimento por parte das redes neurais, apresentando desempenho superior a versão constituída pela base de conhecimento criada a partir dos grafos de conhecimento colhidos dos especialistas. Portanto, pode-se constatar que, sempre que possível, deve-se procurar executar a explicitação automática de conhecimento, por casos reais. A utilização de uma base de

casos deve ser considerada como uma técnica eficaz para a engenharia de conhecimento.

Como principais contribuições deste trabalho pode-se citar:

- a utilização da lógica nebulosa na modelagem de variáveis que possuem predicados e quantificadores associados;

- a aplicação da metodologia de aquisição de conhecimento pela construção de grafos de conhecimento, que demonstrou sua aplicabilidade na engenharia de conhecimento para problemas classificatórios;

- a utilização de técnicas de aprendizagem de máquina para solucionar, ou tornar menos complexa, a aquisição de conhecimento;

- a constatação dos bons resultados no uso do SE no suporte à decisão.

Através dos estudos realizados no decorrer deste trabalho, foi possível verificar os avanços ocorridos na solução de alguns dos problemas encontrados no desenvolvimento de SE, especialmente naqueles relacionados à aprendizagem de máquina. Redes neurais constituem uma metodologia de características fortemente adaptativas, que facilitam a implementação do aprendizado por indução, bem como os algoritmos genéticos em relação ao aprendizado dedutivo.

A incorporação e integração destas técnicas, entre outras, abre caminho para futuras pesquisas e desenvolvimentos de sistemas computacionais que venham a apresentar, cada vez mais, um comportamento inteligente. O trabalho desenvolvido nesta dissertação utilizou um problema decisório onde é necessário analisar-se vários elementos e as possíveis combinações entre eles para determinar-se uma situação futura e, a partir daí, tomar uma decisão. Existem, nas organizações, inúmeros problemas com essas mesmas características, portanto, passíveis de uma abordagem similar à usada aqui. Áreas como a de produção, financeira e de telecomunicações são redutos de problemas críticos e complexos, portanto, certamente, são campos férteis para aplicações candidatas a utilização de SEs. A própria CEEE, no setor de

planejamento e geração de energia, possui outras problemáticas que podem ser analisadas sob a ótica dos SEs, como por exemplo, o problema de controle de alarmes.

Referindo-se especificamente à CEEE, pois foi nesta empresa que ocorreu grande parte do desenvolvimento deste trabalho, existem várias aplicações candidatas ao uso de SEs e outras tecnologias relacionadas à IA. Faz-se necessário prover os recursos humanos, que existem na companhia, de conhecimentos que os permitam fazer uso das tecnologias comentadas neste trabalho, como Sistemas Especialistas, Sistemas Conexionistas, Sistemas Híbridos e Lógica Nebulosa. A criação de um núcleo de pessoas com o objetivo de estudar, trocar informações e verificar aplicações existentes seria uma forma de dar continuidade ao trabalho desenvolvido nesta dissertação, dentro da CEEE. Tanto como os recursos humanos são importantes, os recursos técnicos de hardware e software também o são, para a utilização dessas tecnologias faz-se necessário máquinas com considerável capacidade de memória e processamento, a disponibilidade de máquinas com tais requisitos seria uma segunda exigência para o prosseguimento do trabalho iniciado com esta dissertação na CEEE.

É possível vislumbrar um considerável campo de atuação para sistemas de IA, em específico SE. Uma das maiores restrições ao uso destas tecnologias são, sem dúvida, as limitações impostas pelo hardware. Para que essas tecnologias saiam dos laboratórios e ganhem espaço no uso diário das pessoas, faz-se necessário ambientes de hardware que suportem altos requisitos de memória e processamento. O advento de novos chips processadores, principalmente voltados a máquinas de uso pessoal, vão permitir uma maior difusão e melhor desempenho dessas tecnologias. Paralelamente a isso, é necessário que os dirigentes das organizações estejam sempre atentos e receptivos ao uso e incorporação de tecnologias, conscientes de sua importância estratégica, como fontes de solução de problemas, economia, agilização e melhora de serviços e produtos.

10 CONCLUSÕES

Pelos resultados obtidos no desenvolvimento do trabalho aqui descrito e pela validação do modelo computacional SECOX-HI, pode-se formular as conclusões abaixo relacionadas.

A utilização da lógica nebulosa, mostrou ser esta uma técnica eficiente para a modelagem e interpretação de variáveis que possuem conceitos associados, na forma de predicados do tipo *máximo*, *médio*, *mínimo*, *pouca*, *muito*, etc. A lógica nebulosa permite uma representação muito próxima da realidade para essas situações, evitando simplificações que não representam corretamente a realidade semântica das variáveis.

A metodologia de construção dos grafos de conhecimento demonstrou ser uma ferramenta útil e de fácil aplicação. Os grafos de conhecimento direcionam a aquisição de conhecimento, tornando esta tarefa mais objetiva, pois permitem que se determine e expresse os elementos do domínio, bem como suas relações, de forma coerente e completa. Pode-se concluir que a metodologia de aquisição de conhecimento pela construção de grafos de conhecimento constitui uma técnica eficiente para a engenharia de conhecimento em problemas do tipo classificatório.

A integração dos paradigmas simbólico e conexionista demonstrou ser uma técnica eficiente na representação do conhecimento. As redes neurais possibilitaram a implementação da aquisição automática de conhecimento, enquanto que as estruturas de dados relacionais permitiram uma maior flexibilidade e compreensão do conhecimento representado pelas redes neurais, facilitando a análise e manutenção deste conhecimento.

O mecanismo de inferência, implementado pelo modo de consulta do MNC, apresentou ótimo desempenho. Pode-se verificar a eficiência da aquisição automática de conhecimento, por casos de treinamento. Conclui-se que, dado um banco de casos ou se este for de possível construção, a estratégia de aprendizagem automática por casos reais é a melhor para a aquisição de conhecimento.

REFERÊNCIAS BIBLIOGRÁFICAS

- [BON81] BONCZEK, R. H. **Foundations of Decision Support Systems**. New York: Academic Press, 1981.
- [BUC84] BUCHANAN, BRUCE G.; SHORTLIFFE, EDWARD H. **Rule Based Expert Systems: The MYCIN experiments of the Stanford Heuristic Programming Project**. Massachusetts: Addison-Wesley, 1984.
- [CAR89] CARBONELL, J. G. Introduction: Paradigms for Machine Learning. **Artificial Intelligence**, Amsterdam, V. 40, n. 1-3, p. 1-9, Sept. 1989.
- [COS86] COSTA, A. C. R. **Sobre os fundamentos da inteligência artificial**. Porto Alegre, CPGCC/UFRGS, 1896. (RP. 61/86).
- [HAY83] HAYES-ROTH, F. et al. **Building Expert Systems**. Reading: Addison-Wesley, 1983.
- [KAN92] KANDEL E. R & HAWKINS R. D. The Biological Basis of Learning and Individuality. **Scientific American - Special Issue Mind and Brain**, V. 267, n. 3, pp 48-57, Sept. 1992.
- [KNI89] KNIGHT, K. **A Gentle Introduction to Subsymbolic Computation: Connectionism for the AI Researcher**. Pittsburgh: Carnegie-Mellon University, 1989.
- [KOS92] KOSKO, B. **Neural Networks and Fuzzy Systems**. NJ: Prentice Hall, Englewood Cliffs, 1992.
- [LAW91] LAWRENCE D. **The Handbook of Genetic Algorithms**. New York: Van Nostrand Reinhold, 1991.

- [LEA90] LEÃO, B. F. & ROCHA, A. F. Proposed Methodology for Knowledge Acquisition: A Study on Congenital Heart Disease Diagnosis. **Methods of Information in Medicine**, V. 29, n.1, p. 30-40, 1990.
- [LUC86] LUCONI, F. et al. Expert Systems: the next challenge for managers. **Sloan Management Review**, V. 27, n. 4, p. 3-14, Summer 1986.
- [MAC89] MACHADO, R. J., ROCHA, A. F. **Handling Knowledge in High Order Neural Networks: The Combinatorial Neural Model**. Rio de Janeiro: IBM Rio Scientific Center, 1989. (Technical Report CCR076).
- [MAC90] MACHADO R. J., ROCHA A. F. & LEÃO B. F. Calculating the Mean Knowledge representation from multiple experts. In: FEDREZZI M. & KACPRZKYK J. (eds). **Multiperson Decision Making Models Using Fuzzy Sets and Possibility Theory**, The Netherlands: Kluwer Academic Publishers, 1990.
- [MAC91] MACHADO, R. J. e DENIS, F. A. R. M. **O modelo Conexcionista Evolutivo**. Rio de Janeiro: IBM Rio Scientific Center, 1991. (Technical Report CCR-128).
- [MAR91] MARTINEZ, Raul. **Programacion en reglas de produccion - una introduccion a los sistemas de producciones**. Campinas: R. Vieira Gráfica e Editora, 1991.
- [McC88b] McCLELLAND J. L., RUMELHART D. E. & HINTON G. E. The appeal of parallel distributed processing. **Parallel Distributed Processing**, Vol. 1. Cambridge: The MIT Press, pp. 4-44, 1988.
- [MED92] MEDSKER L. R. & BAILEY D. L. Models and Guidelines for Integrating Expert Systems and Neural Networks. Em: KANDEL A. & LANGHOLZ G. **Hybrid Architectures for Intelligent Systems**, CRC Press, 1992.

- [MIN68] MINSKY, Marvin. **Semantic information processing**. Cambridge: The MIT Press, 1968.
- [MIN72] MINSKY, Marvin, PAPERT, Seymour. **Perceptrons. An Introduction to Computational Geometry**. Cambridge: The MIT Press, 1990.
- [NIL80] NILSSON, N. J. **Principles of Artificial Intelligence**. Palo Alto, CA: Tioga, 1980.
- [OWE90] OWENS D. K. et al. Medical Decision Making: Probabilistic Medical Reasoning. In: SHORTLIFE E. H. et al. (eds.). **Medical Informatics - Computer Applications in Health Care**, Reading, Addison-Wesley Publishing Company, p. 70-116, 1990.
- [PAC91] PACHECO, R. C. dos Santos. **Tratamento de Imprecisão em Sistemas Especialistas**. Florianópolis, UFSC, 1991.(Dissertação de mestrado em engenharia de produção).
- [PAS93] PASTORELLO, Marco Antonio. **Técnicas de explanação em sistemas especialistas: a explanação why not**. Porto Alegre, CPGCC/UFRGS, 1993 (Dissertação de mestrado em ciência da computação).
- [PRE89] PRERAU, D. Choosing an Expert System Domain. In: G. Guida and C. Tasso (eds.). **Topics in Expert Systems Design, Methodologies and Tools**. Amsterdam: North-Holland Publishing Company, 1989.
- [REA93] REÁTEGUI, E. B. **Um modelo para sistemas especialistas conexionistas híbridos**. Porto Alegre: Instituto de Informática da UFRGS, 1993 (Dissertação de mestrado em ciência da computação).
- [RIC83] RICH, Elaine. **Artificial Intelligence**. New York: MacGraw-Hill, 1983. 436p.

- [ROL88] ROLSTON, David. **Principles of Artificial Intelligence and Expert Systems Development**. New York: McGraw-Hill, 1988.
- [SCH82] SCHANK, R. **Dynamic Memory: A Theory of Reminding and Learning in Computers and People**. New York: Cambridge University Press, 1982.
- [SCH92] SCHANK, R. What is AI, anyway ? In: D. Partridge and Y. Wilks (eds.) **The Foundations of Artificial Intelligence**. Cambridge: Cambridge University Press, 1992.
- [SIM81] SIMON, H. **Sciences of the Artificial**. Cambridge: The MIT Press, 1981.
- [VIO93] VIOT, G. "Fuzzy Logic: Concepts to Constructs", **AI EXPERT**, November, 1993, pp. 26-33.
- [ZAD65] ZADEH, L. A. Fuzzy Sets. **Information and Control**, 8, pp. 338-353, 1965.
- [ZAD83] ZADEH, L. A. The Role of Fuzzy Logic in the Management of Uncertainty in Expert Systems. **Fuzzy Sets and Systems**, 11, pp. 199-227, 1983.
- [ZAD86] ZADEH, L. A. Is Probability Theory Sufficient for Dealing with Uncertainty in AI: A Negative View. In: L. N. Kanal and J. F. Lemmer (eds.). **Uncertainty in Artificial Intelligence**. Amsterdam: North-Holland, pp. 103-116, 1986.
- [ZIM85] ZIMMERMANN, H. J. **Fuzzy Set Theory and its Applications**. Boston: Kluwer, 1985.

ANEXO A

Os objetos que compõem a classe evidências:

- E1 - Variação alta da vazão
- E2 - Variação média da vazão
- E3 - Variação baixa da vazão
- E4 - Precipitação alta em RPRE
- E5 - Precipitação média em RPRE
- E6 - Precipitação baixa em RPRE
- E7 - Precipitação alta na bacia hidrográfica dia atual
- E8 - Precipitação média na bacia hidrográfica dia atual
- E9 - Precipitação baixa na bacia hidrográfica dia atual
- E10 - Precipitação alta na bacia hidrográfica dia anterior
- E11 - Precipitação média na bacia hidrográfica dia anterior
- E12 - Precipitação baixa na bacia hidrográfica dia anterior
- E13 - Precipitação alta na bacia hidrográfica dois dias atrás
- E14 - Precipitação média na bacia hidrográfica dois dias atrás
- E15 - Precipitação baixa na bacia hidrográfica dois dias atrás
- E16 - Defluência turbinada alta
- E17 - Defluência turbinada média
- E18 - Defluência turbinada baixa
- E19 - Vazão afluente PBV alta para emergência
- E20 - Vazão afluente PBV alta para vertimento
- E21 - Vazão afluente PBV alta para alerta
- E22 - Vazão afluente PBV média para vertimento
- E23 - Vazão afluente PBV média para alerta
- E24 - Vazão afluente PBV baixa para vertimento

E25 - Vazão afluente PBV baixa para alerta

E26 - Defluência vertida alta

E27 - Defluência vertida média

E28 - Defluência vertida baixa

E29 - Nível do reservatório PRE acima de 0.50 m

E30 - Nível do reservatório PRE entre [0.40 ; 0.50] m

E31 - Nível do reservatório PRE entre [0.20 ; 0.40] m

E32 - Nível do reservatório PRE entre [0.00 ; 0.20] m

E33 - Nível do reservatório PRE entre [-1.27 ; 0.00] m

E34 - Nível do reservatório PRE entre [-1.40 ; -1.27] m

E35 - Nível do reservatório PRE entre [-1.55 ; -1.40] m

E36 - Nível do reservatório PRE entre [-1.70 ; -1.55] m

ANEXO B

Estão relacionadas abaixo as listas com as evidências, para cada objeto da classe diagnóstico.

*** Lista de evidências ordenadas e ponderadas para diagnóstico operação em regime de emergência:**

Peso	Evidências
(10)	1 - Nível do reservatório PRE acima de 0.50 m;
(9.5)	2 - Nível do reservatório PRE entre [0.40;0.50] m;
(9.3)	3 - Nível do reservatório PRE entre [0.20;0.40] m;
(9.1)	4 - Nível do reservatório PRE entre [0.00;0.20] m;
(9.0)	5 - Vazão afluyente alta em PBV para emergência;
(9.0)	6 - Defluência vertida baixa;
(8.6)	7 - Defluência vertida média;
(8.5)	8 - Variação alta da vazão;
(8.3)	9 - Defluência vertida alta;
(8.0)	10 - Precipitação alta na bacia hidrográfica, dia atual;
(5.0)	11 - Precipitação alta na bacia hidrográfica, dia anterior;
(4.0)	12 - Precipitação média na bacia hidrográfica, dia anterior;
(3.0)	13 - Precipitação alta na bacia hidrográfica, dois dias atrás;
(2.0)	14 - Precipitação alta na usina Passo Real;
(2.0)	15 - Precipitação média na bacia hidrográfica, dois dias atrás;
(1.0)	16 - Precipitação baixa na bacia hidrográfica, dia anterior;
(0.5)	17 - Precipitação baixa na bacia hidrográfica, dois dias atrás.

*** Lista de evidências ordenadas e ponderadas para diagnóstico operação em regime de vertimento:**

Peso Evidências

- (10) 1 - Nível do reservatório PRE entre [-1.27;0.00] m;
- (9.5) 2 - Nível do reservatório PRE entre [-1.40;-1.27] m;
- (9.0) 3 - Nível do reservatório PRE entre [-1.55;-1.40] m;
- (8.5) 4 - Nível do reservatório PRE entre [-1.70;-1.55] m;
- (8.0) 5 - Vazão afluente PBV alta para vertimento;
- (8.0) 6 - Precipitação alta na bacia hidrográfica, dia atual;
- (7.5) 7 - Variação alta da vazão;
- (6.5) 8 - Variação média da vazão;
- (6.0) 9 - Vazão afluente PBV média para vertimento;
- (6.0) 10 - Precipitação média na bacia hidrográfica, dia atual;
- (6.0) 11 - Defluência turbinada baixa;
- (5.0) 12 - Precipitação alta na bacia hidrográfica, dia anterior;
- (5.0) 13 - Defluência turbinada média;
- (4.0) 14 - Vazão afluente PBV baixa para vertimento;
- (4.0) 15 - Defluência turbinada alta;
- (3.0) 16 - Precipitação média na bacia hidrográfica, dia anterior.

*** Lista de evidências ordenadas e ponderadas para diagnóstico operação em regime de alerta:**

Peso Evidências

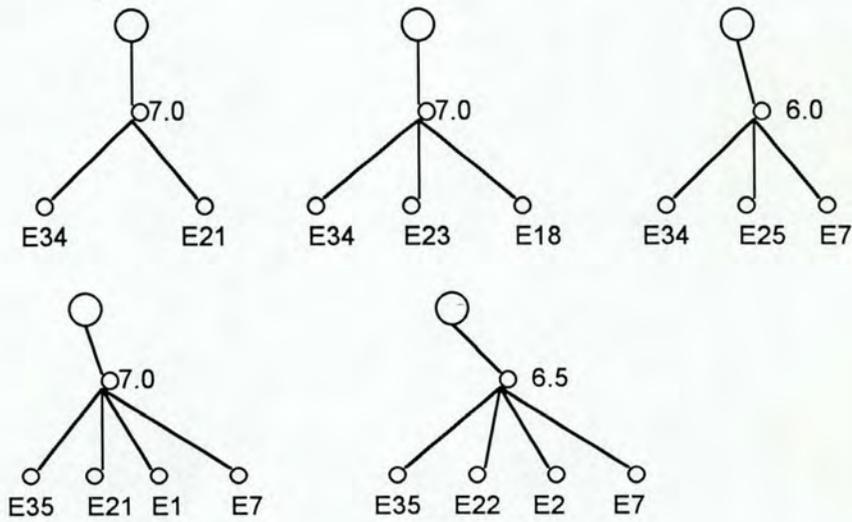
- (10) 1 - Nível do reservatório PRE entre [-1.40;-1.27] m;
- (9.5) 2 - Nível do reservatório PRE entre [-1.55;-1.40] m;
- (9.0) 3 - Nível do reservatório PRE entre [-1.70;-1.55] m;
- (8.0) 4 - Vazão afluente PBV alta para alerta;
- (8.0) 5 - Precipitação alta na bacia hidrográfica, dia atual;

- (8.0) 6 - Defluência turbinada baixa;
- (7.5) 7 - Variação alta da vazão;
- (7.0) 8 - Defluência turbinada média;
- (6.5) 9 - Variação média da vazão;
- (6.0) 10 - Precipitação média na bacia hidrográfica, dia atual;
- (6.0) 11 - Defluência turbinada alta;
- (5.0) 12 - Vazão afluyente PBV média para alerta;
- (5.0) 13 - Precipitação alta na bacia hidrográfica, dia anterior;
- (3.0) 14 - Precipitação média na bacia hidrográfica, dia anterior;
- (1.0) 15 - Vazão afluyente PBV baixa para alerta.

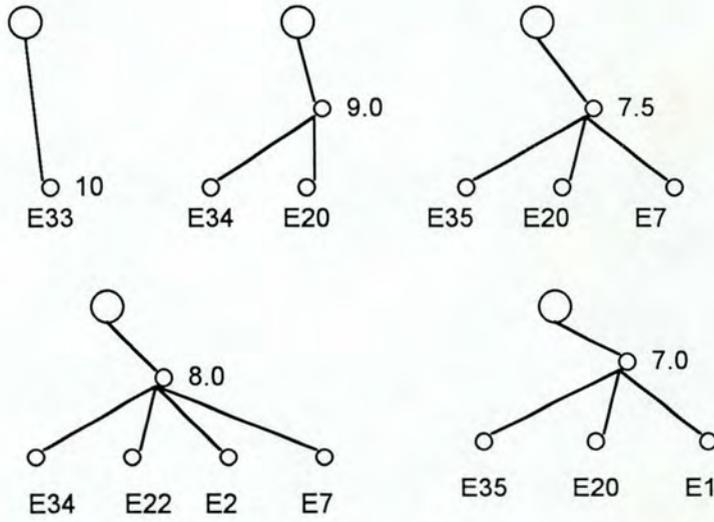
ANEXO C

Estão relacionados abaixo alguns grafos de conhecimento, colhidos dos especialistas, para os regimes de operação **alerta**, **vertimento** e **emergência**. Os nodos de entrada dos grafos, correspondem as evidências citadas no anexo A, são utilizados os mesmos código de evidências do anexo A. Os pesos dos nodos de entrada estão relacionados no anexo B.

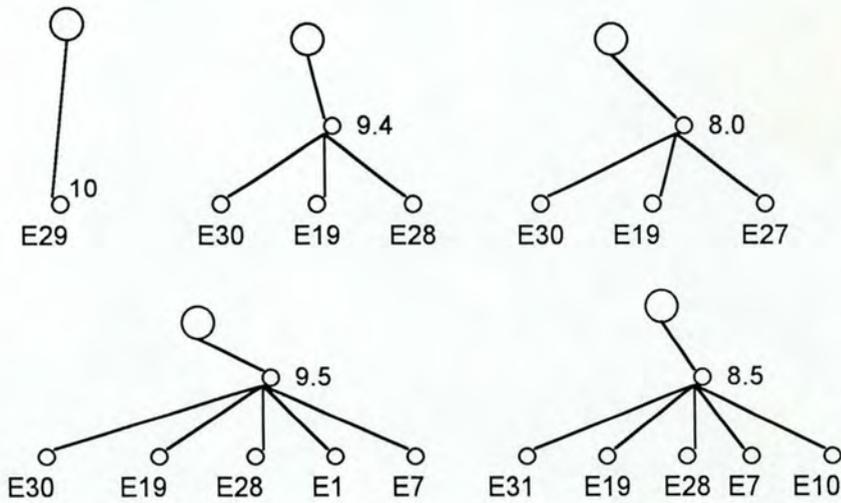
Grafos de conhecimento para diagnóstico regime de **alerta**:



Grafos de conhecimento para diagnóstico regime de **vertimento**:



Grafos de conhecimento para diagnóstico regime de **emergência**:



ANEXO D

Planilha de "Dados Hidrológicos Mensais do RPRE", obtida no Centro de Operações do Sistema, na CEEF.

DADOS HIDROLOGICOS MENSIS DO RPRE											JUL / 87		
PREC	NIVEIS	ARMAZENAMENTO			GERA	CONS	VERT	VAZ.AFLUENTE		V.DEFL			
		MM	MED	8 ho				%	Hm3		MWmes	MWM	m3/s
1	15	-1.63	89.4	3000.8	2342.5	59.8	143.5	0.0	339.1	319.3	143.5		
2	3	-1.60	89.6	3007.1	2347.7	74.6	180.6	0.0	253.5	241.1	180.6		
3	31	-1.43	90.7	3043.2	2376.5	80.4	198.7	0.0	616.5	669.0	198.7		
4	0	-1.18	92.3	3096.8	2418.4	36.0	85.6	0.0	706.0	718.5	85.6		
5	0	-1.03	93.2	3129.1	2442.0	62.9	149.7	0.0	523.5	511.3	149.7		
SEM	103	-1.48	90.4	3032.9	2367.9	66.6	160.6	0.0	418.0	421.0	160.6		
6	50	-0.90	94.1	3157.4	2465.6	117.4	273.7	0.0	601.2	694.4	273.7		
7	0	-0.84	94.4	3170.4	2473.5	142.5	332.6	250.4	733.5	916.8	583.0		
8	0	-0.79	94.8	3181.4	2483.9	137.5	320.0	522.1	969.4	968.5	842.1		
9	0	-0.79	94.8	3181.4	2483.9	136.0	316.5	600.4	916.9	845.5	916.9		
10	0	-0.79	94.8	3181.4	2483.9	140.2	326.5	328.3	654.8	598.8	654.8		
11	25	-0.83	94.5	3172.6	2476.1	135.7	316.1	283.7	498.0	491.8	599.8		
12	0	-0.85	94.4	3168.3	2473.5	142.7	333.2	304.5	587.9	580.3	637.7		
SEM	75	-0.83	94.5	3173.3	2477.2	136.0	316.9	327.1	708.8	728.0	644.0		
13	0	-0.86	94.3	3166.1	2470.8	136.1	317.3	202.9	494.7	453.8	520.2		
14	0	-0.89	94.1	3159.5	2465.6	134.6	314.1	149.8	387.5	367.8	463.9		
15	0	-0.90	94.1	3157.4	2465.6	135.7	316.7	76.7	369.1	341.2	393.4		
16	0	-0.94	93.8	3148.7	2457.7	136.5	319.1	44.4	262.8	236.1	363.5		
17	0	-0.98	93.5	3140.0	2449.9	136.0	318.2	73.7	291.2	271.5	391.9		
18	0	-0.98	93.5	3140.0	2449.9	107.1	251.0	0.0	251.0	270.9	251.0		
19	0	-0.98	93.5	3140.0	2449.9	110.0	257.7	0.0	257.7	264.4	257.7		
SEM	0	-0.93	93.8	3150.2	2458.5	128.0	299.2	78.2	330.6	315.1	377.4		
20	0	-1.00	93.4	3135.6	2447.3	138.3	324.1	0.0	273.2	254.0	324.1		
21	0	-1.03	93.2	3129.1	2442.0	136.5	319.8	0.0	244.6	231.4	319.8		
22	0	-1.05	93.1	3124.8	2439.4	130.4	305.6	0.0	255.8	242.3	305.6		
23	2	-1.09	92.8	3116.2	2431.5	138.8	326.1	0.0	226.6	206.4	326.1		
24	0	-1.11	92.7	3111.8	2428.9	131.8	309.4	0.0	258.5	246.4	309.4		
25	0	-1.15	92.4	3103.2	2421.1	138.8	326.8	0.0	227.3	214.0	326.8		
26	5	-1.21	92.1	3090.3	2413.2	136.7	322.1	0.0	172.8	153.3	322.1		
SEM	7	-1.09	92.8	3115.9	2431.9	135.9	319.1	0.0	237.0	221.1	319.1		
27	92	-1.14	92.5	3105.4	2423.7	133.6	314.0	2.8	491.6	536.5	316.8		
28	61	-0.87	94.3	3163.9	2470.8	114.8	267.6	9.1	953.8	1284.5	276.7		
29	13	-0.76	95.0	3187.9	2489.2	142.9	332.8	756.8	1367.4	1531.1	1089.6		
30	0	-0.69	95.4	3203.3	2499.7	143.4	333.5	1152.6	1664.3	1618.4	1486.1		
31	0	-0.72	95.2	3196.7	2494.4	144.2	335.6	1239.2	1498.4	1395.1	1574.8		
MES	297	-1.00	93.4	3135.8	2447.7	122.3	286.7	193.5	559.6	570.1	480.2		

VERIFICAR ESSES DIAS NA PLANILHA DE DADOS DO RPRE

ANEXO F

Neste anexo encontram-se algumas planilhas montadas a partir das planilhas contidas nos anexos D e E, para compor o banco de casos. -18.

DATA		16/9/89	23/9/89	23/9/89	23/6/89	23/9/89	24/9/89
NÍVEL RPRE (M)		-0,60	-0,83	-0,77	-0,73	-0,64	-0,54
AFLUENCIA PBV (M3/S)		915	918	1232	1500	2609	3371
V. VAZÃO (M3/S/H)		181	353	136	268	0	48
PRECP RPRE (MM/DIA)		0	40,2	40,2	40,2	40,2	0
PRECP BACIA HIDRO D1 (MM/DIA)	MAIA FILHO	0	38,4	37,4	38,4	38,4	0
	ITAUBA	0	25,6	25,6	25,6	25,6	0
	ERNESTINA	0	115,8	115,8	115,8	115,8	0
	PBV	0	60,2	60,2	60,2	60,2	0
	ESPUMOSO	0	62,4	62,4	62,4	62,4	0
	CAPIGUI	0	95	95	95	95	158
PRECP BACIA HIDRO D2 (MM/DIA)	MAIA FILHO	0	73,4	73,4	73,4	73,4	38,4
	ITAUBA	0	53,4	53,4	53,4	53,4	25,6
	ERNESTINA	0	82,9	82,9	82,9	82,9	115,8
	PBV	0	-	-	-	-	60,2
	ESPUMOSO	0	?	?	?	?	62,4
	CAPIGUI	0	63,0	63,0	63,0	63,0	95
PRECP BACIA HIDRO D3 (MM/DIA)	MAIA FILHO	9,3	0	0	0	0	73,4
	ITAUBA	5,6	3,6	3,0	3,6	3,6	53,4
	ERNESTINA	8,3	0,4	0,4	0,4	0,4	82,9
	PBV	6,4	2	2	2	2	-
	ESPUMOSO	-	-	-	-	-	?
	CAPIGUI	10,2	0	0	0	0	63
VAZÃO TURBINADA (M3/S)		330,7	330,3	330,3	330,3	330,3	326,3
VAZÃO VERTIDA (M3/S)		562,5	552,0	552,0	552,0	552,0	1760,9
REGIME		VERTIMENT.	VERTIMENT.	VERTIMENT.	VERTIMENT.	VERTIMENT.	VERTIMENT.

VAZÃO TURBINADA → BANCO
 VAZÃO VERTIDA → BANCO
 ? → BANCO

DATA		25/9/89	25/9/89	26/9/89	27/9/89	27/9/89	27/9/89	27/9/89	27/9/89	27/9/89	27/9/89	27/9/89	27/9/89
NÍVEL RPRE (M)		-0,45	-0,43	-0,45	-0,55	-7,70	-7,69						
AFLUENCIA PBV (M3/S)		3257	3077	2676	1787	1157	1244						
V. VAZÃO (M3/S/H)		0	-16	-6	0	15	87						
PRECP RPRE (MM/DIA)		0	0	0	0	76,0	76,0						
PRECP BACIA HIDRO D1 (MM/DIA)	MAIA FILHO	0	0	0	0	58,4	58,4						
	ITAUBA	0	0	0	0	60,7	69,8						
	ERNESTINA	0	0	0	0	72,6	72,0						
	PBV	0	0	0	0	67,5	67,5						
	ESPUMOSO	0	0	0	0	-	-						
	CAPIGUI	0	0	0	0	80,1	80,1						
PRECP BACIA HIDRO D2 (MM/DIA)	MAIA FILHO	0	0	0	0	53,4	53,4						
	ITAUBA	0	0	0	0	39,9	39,9						
	ERNESTINA	0	0	0	0	57	57						
	PBV	0	0	0	0	43	43						
	ESPUMOSO	0	0	0	0	-	-						
	CAPIGUI	158	158	0	0	49,2	49,2						
PRECP BACIA HIDRO D3 (MM/DIA)	MAIA FILHO	38,4	38,4	0	0	1,0	1,0						
	ITAUBA	25,6	25,6	0	0	0	0						
	ERNESTINA	115,8	115,8	0	0	6,1	6,1						
	PBV	60,2	60,2	0	0	0	0						
	ESPUMOSO	62,4	62,4	0	0	0	0						
	CAPIGUI	95	95	158	0	3,1	3,1						
VAZÃO TURBINADA (M3/S)		326,4	326,4	329,9	335,6	123,1	123,1						
VAZÃO VERTIDA (M3/S)		2000,5	2000,5	1819,1	1052,9	0	0						
REGIME		VERTIMENTOS	VERTIMENTOS	VERTIMENTOS	VERTIMENTOS	ALERTA	ALERTA						