

UNIVERSIDADE DO EXTREMO SUL CATARINENSE - UNESC
CURSO DE CIÊNCIA DA COMPUTAÇÃO

LEONARDO ASSIS DA SILVA

**O FORMALISMO DA TEORIA DE DEMPSTER-SHAFER NA *SHELL* PARA
MODELAGEM DA INCERTEZA PEGASUS**

CRICIÚMA, JULHO DE 2008

LEONARDO ASSIS DA SILVA

**O FORMALISMO DA TEORIA DE DEMPSTER-SHAFFER NA *SHELL* PARA
MODELAGEM DA INCERTEZA PEGASUS**

Trabalho de Conclusão de Curso
apresentado para a obtenção do Grau de
Bacharel em Ciência da Computação da
Universidade do Extremo Sul Catarinense.

Orientadora: Prof^ª. MSc. Priscyla Waleska
Targino de Azevedo Simões.

CRICIÚMA, JULHO DE 2008

LEONARDO ASSIS DA SILVA

**O FORMALISMO DA TEORIA DE DEMPSTER-SHAFER NA
SHELL PARA MODELAGEM DA INCERTEZA PEGASUS**

Submetido ao corpo docente do Curso de Ciência da Computação da Universidade do Extremo Sul Catarinense como um dos requisitos para obtenção do grau de Bacharel em Ciência da Computação.

Profa. MSc. Ana Claudia Garcia Barbosa
Coordenadora do Curso de Ciência da Computação

Banca Examinadora:

Profa. MSc. Priscyla Waleska Targino de Azevedo Simões (UNESC)
Orientadora

Profa. MSc. Merisandra Côrtes de Matos (UNESC)

Profa. Esp. Alair Salete Budni Morais (UNESC)

A Jaqueline.

AGRADECIMENTOS

Aos meus pais, que sempre incentivaram a continuação dos meus estudos, me dando o apoio para que eu pudesse concluir este curso de graduação.

À minha irmã e sua família por toda ajuda que me deram, que com certeza foi fundamental na minha vida.

Aos meus amigos, por terem me alegrado nas horas difíceis, muito obrigado pela amizade e apoio durante todo esse tempo.

À minha orientadora Priscyla pela atenção e principalmente paciência que teve durante a realização deste trabalho e também pela amizade durante todo o curso de graduação.

À minha namorada, por me dar todo apoio necessário, compreender minha ausência em alguns momentos e me ajudar nas horas mais difíceis.

“O primeiro sinal de ignorância é
presumirmos que sabemos.”

Baltasar De Gracian

RESUMO

Durante os últimos 20 anos os sistemas baseados em paradigmas de Inteligência Artificial (IA) têm sido amplamente utilizados em diversas áreas. Durante o emprego desses sistemas, muitas vezes o conhecimento adquirido é incompleto ou imperfeito, fazendo com que atuem sobre dados incertos ou vagos. Nesse contexto, a teoria de Dempster-Shafer (TDS) utiliza graus de crença com intervalos de probabilidade para representar o conhecimento incerto, calculando a chance de uma evidência assumir uma determinada hipótese. Assim, esta pesquisa abrange o desenvolvimento da inferência de Dempster-Shafer em uma *shell* denominada Pegasus *Uncertain Modeling*, idealizada pelo grupo de pesquisa em Inteligência Computacional Aplicada da Universidade do Extremo Sul Catarinense. Esta pesquisa resultou em um aplicativo desenvolvido na linguagem Java a partir do ambiente NetBeans IDE 6.0.1, que compreende o módulo da TDS que foi integrado à *shell* Pegasus. Foram feitos alguns testes comparando os resultados obtidos com o *software* Dempster-Shafer *Engine* para determinar a precisão dos cálculos, os quais foram considerados satisfatórios.

Palavras-chave: Inteligência Artificial; Motor de Inferência; Modelagem da Incerteza; Teoria da Evidência de Dempster-Shafer; *Shell* para Modelagem de Incertezas.

ABSTRACT

During the past 20 years, systems based on paradigms of Artificial Intelligence (AI) have been widely used in various areas. During the use of these systems, often the knowledge gained is incomplete or flawed, making them act upon uncertain or vague data. In this context, Dempster-Shafer's theory (DST) uses degrees of belief with breaks of probability to represent the uncertain knowledge, calculating the chance of an evidence becoming a particular hypothesis. Thus, this research includes the development of the inference of Dempster-Shafer in a shell called *Pegasus Uncertainty Modeling*, by the Applied Computational Intelligence research group at *Universidade do Extremo Sul Catarinense* (University of the Extreme South of Santa Catarina). This research has resulted in an application developed in Java from the environment NetBeans IDE 6.0.1, which includes the TDS module which has been integrated into the *shell* Pegasus. Some tests were done, comparing the results obtained with Dempster-Shafer *Engine software* to determine the accuracy of the calculations, which were considered satisfactory.

Keywords: Artificial Intelligence; Inference Engine; Uncertainty Modeling; Dempster-Shafer's Theory of Evidence; *Shell* for Modeling of Uncertainties.

LISTA DE ILUSTRAÇÕES

| | |
|---|----|
| Figura 1. Diferentes variáveis lingüísticas para a variável temperatura | 24 |
| Figura 2. Conjunto de todas as hipóteses possíveis a partir de $\Theta = \{v,e,h,a\}$ | 34 |
| Figura 3. Estrutura geral de um SE | 42 |
| Figura 4. Classificação da crença nas classes utilizando a TDS | 57 |
| Figura 5. Comportamento do Sinal de Tráfego..... | 58 |
| Figura 6. Processo de agregação baseado na inferência da TDS | 62 |
| Figura 7. Interface do Dempster-Shafer <i>Engine</i> | 65 |
| Figura 8. Base de Conhecimento da lombalgia..... | 69 |
| Figura 9. Base de Conhecimento da lombalgia preenchida pelo especialista 1..... | 70 |
| Figura 10. Base de Conhecimento da lombalgia preenchida pelo especialista 2..... | 72 |
| Figura 11. Modelagem do módulo baseado na TDS..... | 81 |
| Figura 12. Modelagem do MI | 81 |
| Figura 13. Diagrama de Casos de Uso | 83 |
| Figura 14. Diagrama de Classes..... | 84 |
| Figura 15. Classe <i>Hipotesys</i> | 84 |
| Figura 16. Construtores da classe <i>Hipotesys</i> | 85 |
| Figura 17. Métodos de acesso aos atributos da classe <i>Hipotesys</i> | 85 |
| Figura 18. Classe <i>Evidence</i> | 86 |
| Figura 19. Classe <i>Evidences</i> | 86 |
| Figura 20. Classe <i>Inference</i> | 88 |
| Figura 21. Pseudocódigo | 90 |
| Figura 22. Interface | 91 |
| Figura 23. Interface de manutenção da lista de hipóteses..... | 92 |

| | |
|---|-----|
| Figura 24. Cadastro de hipóteses | 92 |
| Figura 25. Lista das hipóteses | 92 |
| Figura 26. Interface de manutenção da lista de evidências | 93 |
| Figura 27. Cadastro de evidências | 94 |
| Figura 28. Lista das evidências cadastradas exibidas na interface..... | 94 |
| Figura 29. Seleção de um item da lista das evidências para exibição das informações.. | 95 |
| Figura 30. Cadastro das hipóteses na <i>shell</i> Pegasus e na ferramenta DSE | 96 |
| Figura 31. Cadastro das evidências | 97 |
| Figura 32. Cadastro dos especialistas na ferramenta DSE..... | 97 |
| Figura 33. Cadastro das evidências na ferramenta DSE | 98 |
| Figura 34. Combinação das evidências | 98 |
| Figura 35. Resultados da combinação das evidências dos especialistas | 98 |
| Figura 36. Resultados da combinação das evidências dos especialistas na DSE..... | 99 |
| Figura 37. Botão da inferência | 99 |
| Figura 38. Interface dos resultados da inferência..... | 100 |
| Figura 39. Hipóteses na interface dos resultados da inferência | 100 |
| Figura 40. Gráfico dos Resultados | 101 |
| Figura 41. Gráfico Comparativo dos Resultados | 101 |
| Figura 42. Classe da Interface | 113 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1. Comparação entre os formalismos para a modelagem da incerteza..... | 30 |
| Tabela 2. Utilização da regra de Dempster na distribuição de crenças para m_3 | 46 |
| Tabela 3. Utilização da regra de Dempster para demonstrar o peso de conflito..... | 51 |
| Tabela 4. Comparação entre a TDS e a lógica bayesiana | 54 |
| Tabela 5. Combinação das evidências no caso da lombalgia para obtenção de m_3 | 74 |
| Tabela 6. Combinação das evidências no caso da lombalgia para obtenção de m_4 | 77 |

LISTA DE SIGLAS

| | |
|------------|---|
| BC | Base de Conhecimento |
| <i>bpa</i> | <i>basic probability assignment</i> |
| FC | Fator de Certeza |
| H-E | Hassi-Euler |
| IA | Inteligência Artificial |
| INPE | Instituto Nacional de Pesquisas Espaciais |
| MC | Medida de Crença |
| MCD | Módulo Coletor de Dados |
| MD | Medida de Descrença |
| MI | Motor de Inferência |
| MT | Memória de Trabalho |
| NS | Núcleo do Sistema |
| SAD | Sistemas de Apoio à Decisão |
| SE | Sistemas Especialistas |
| TDS | Teoria de Dempster-Shafer |

SUMÁRIO

| | |
|---|-----------|
| 1 INTRODUÇÃO | 15 |
| 1.1 OBJETIVO GERAL | 17 |
| 1.2 OBJETIVOS ESPECÍFICOS..... | 18 |
| 1.3 JUSTIFICATIVA..... | 18 |
| 1.4 ESTRUTURA DO TRABALHO..... | 20 |
| 2 MODELAGEM DA INCERTEZA..... | 21 |
| 2.1 TEOREMA DE BAYES | 21 |
| 2.2 LÓGICA <i>FUZZY</i> | 23 |
| 2.3 TEORIA DOS FATORES DE CERTEZA | 25 |
| 2.4 TEORIA DE DEMPSTER-SHAFER | 27 |
| 2.5 COMPARATIVO DAS TEORIAS | 29 |
| 3 TEORIA DA EVIDÊNCIA DE DEMPSTER-SHAFER..... | 31 |
| 3.1 DOMÍNIO DO PROBLEMA | 32 |
| 3.2 CONCEITOS BÁSICOS | 34 |
| 3.3 FUNÇÃO DE CRENÇA E PLAUSIBILIDADE | 37 |
| 3.4 A REGRA DE DEMPSTER..... | 39 |
| 3.5 INFERÊNCIA PELA TEORIA DE DEMPSTER-SHAFER | 42 |
| 3.6 EXEMPLO DE INFERÊNCIA..... | 44 |
| 3.7 PESO DE CONFLITO..... | 48 |
| 3.8 RELAÇÃO ENTRE AS TEORIAS BAYESIANA E DE DEMPSTER-SHAFER.. | 52 |
| 4 TRABALHOS CORRELATOS..... | 55 |
| 4.1 APLICAÇÕES | 55 |
| 4.1.1 A Teoria da Incerteza Aplicada à Classificação de Imagens de Satélite..... | 55 |

| | |
|---|-----------|
| 4.1.2 Detecção de Falhas em Redes de Sensores sem Fio Baseada na Medição do Tráfego e em Técnicas de Fusão de Dados | 57 |
| 4.1.3 Incerteza e Combinação de Evidências: A Questão dos Diamantes do Rio Tibagi-PR..... | 59 |
| 4.1.4 Investigação Sobre o uso de Dados Auxiliares no Processo de Classificação de Imagens Digitais Empregando Princípios da Teoria da Evidência..... | 60 |
| 4.1.5 Mecanismo de Agregação de Dados Empregando Técnicas Paramétricas em Redes de Sensores | 61 |
| 4.1.6 A Teoria de Dempster-Shafer como um Método de Inferência para Reconhecimento de Imagens Geométricas Distorcidas..... | 63 |
| 4.2 FERRAMENTA..... | 64 |
| 4.2.1 Dempster-Shafer Engine | 64 |
| 5 O FORMALISMO DA TEORIA DE DEMPSTER-SHAFER NA SHELL PARA MODELAGEM DA INCERTEZA PEGASUS..... | 67 |
| 5.1 LEVANTAMENTO BIBLIOGRÁFICO..... | 67 |
| 5.2 MODELAGEM MATEMÁTICA..... | 68 |
| 5.3 MODELAGEM DO MOTOR DE INFERÊNCIA | 80 |
| 5.4 MODELAGEM E IMPLEMENTAÇÃO DO <i>SOFTWARE</i> | 82 |
| 5.4.1 Classe <i>Hipotesys</i> | 84 |
| 5.4.2 Classe <i>Evidence</i> | 85 |
| 5.4.3 Classe <i>Evidences</i> | 86 |
| 5.4.4 Classe <i>Inference</i> | 88 |
| 5.4.5 Classe <i>Interface</i> | 89 |
| 5.4.6 Interface do Aplicativo | 90 |
| 5.4.6.1 Definição da Base de Conhecimento | 91 |

| | |
|--|------------|
| 5.5 TESTES | 95 |
| 5.6 RESULTADOS OBTIDOS | 99 |
| CONCLUSÃO | 103 |
| REFERÊNCIAS | 105 |
| BIBLIOGRAFIA RECOMENDADA | 111 |
| APÊNDICE A – CLASSE DA INTERFACE | 113 |
| APÊNDICE B – ARTIGO | 116 |
| ANEXO A – PROJETO DO PIBIC | 126 |
| ANEXO B – DIAGNÓSTICO DA LOMBALGIA..... | 127 |

1 INTRODUÇÃO

Durante os últimos 20 anos os sistemas baseados em paradigmas de Inteligência Artificial (IA) têm sido amplamente utilizados em diversas áreas, como a Medicina e a Engenharia, entre outras. Assim, a IA costuma contribuir em diferentes áreas de aplicação quando existem problemas que, devido a sua complexidade, exigem grande quantidade de conhecimento e raciocínio. Desse modo, para lidar com esses problemas muitas vezes são desenvolvidos os chamados sistemas inteligentes (REZENDE, 2005).

Esses sistemas geralmente são criados para a resolução de problemas de domínios específicos, como é o caso do MYCIN, que foi desenvolvido em 1974 para a área médica com o propósito de diagnosticar infecções sanguíneas, e do DENDRAL que foi desenvolvido em 1971 na especialidade de química orgânica com o objetivo de determinar um conjunto de estruturas moleculares a partir de átomos conhecidos (BUCHANAN; SHORTLIFFE, 1984; LINDSAY et al, 1980).

Esses tipos de sistemas costumam ser desenvolvidos por meio de ferramentas denominadas *shells*, como o Netica, desenvolvido pela Norsys Software Corporation, que permite a implementação da inferência Bayesiana em sistemas especialistas probabilísticos, e o Expert SINTA (NOGUEIRA, 1996), desenvolvido pelo grupo de Sistemas Inteligentes Aplicados da Universidade Federal do Ceará, que permite a inferência baseada em regras com a utilização de fatores de confiança.

As ferramentas da IA geralmente oferecem uma interface que facilita a construção do motor de inferência, que tem como uma de suas aplicações a modelagem da incerteza. Durante a utilização de um sistema especialista, muitas vezes o conhecimento adquirido é incompleto ou imperfeito, fazendo com que os sistemas

atuem sobre dados incertos ou vagos. Por não existir uma teoria genérica que consiga modelar todos os tipos de incerteza, a escolha de um método para a sua representação no motor de inferência é um problema enfrentado durante o desenvolvimento dos Sistemas Especialistas (SE) (BITTENCOURT, 2001).

Os tipos de incerteza são classificados de diversas maneiras e para cada uma existe pelo menos um formalismo associado a sua modelagem. Os modelos formais mais conhecidos que utilizam propriedades matemáticas são: a lógica *fuzzy*, o Teorema de Bayes, os Fatores de Certeza e a Teoria de Dempster-Shafer (TDS) (RUSSEL; NORVIG, 2004).

A lógica *fuzzy* é utilizada para a modelagem da incerteza por imprecisão que apresenta um tipo de informação que não possui seus limites precisamente definidos, como no exemplo citado por Russel e Norvig (2004) no qual é considerado que uma pessoa com 1,78m de altura pode ser alta para alguns, mas baixa para outros.

O Teorema de Bayes, também chamado de modelo probabilista, é utilizado para modelagem da incerteza por aleatoriedade. Um exemplo da utilização desse formalismo pode ser encontrado na previsão do tempo, onde é calculada a probabilidade de algum evento climático acontecer (COSTA; SIMÕES, 2004).

Assim como o método bayesiano, a teoria dos Fatores de Certeza, também utiliza um único valor para quantificar a incerteza, o Fator de Certeza (FC), que indica o grau de certeza de uma regra ou afirmação. O FC é dividido em duas partes, a Medida de Crença (MC) e a Medida de Descrença (MD), a MC representa a confiança em uma afirmação tendo ocorrido uma determinada evidência e a MD mostra o grau de descrença na mesma afirmação com a ocorrência da evidência (COSTA; SIMÕES, 2004).

Diferente destes formalismos, a TDS utiliza graus de crença com intervalos de probabilidade, para representar o conhecimento incerto. Assim, ao contrário de calcular a probabilidade de uma proposição, a TDS calcula a chance de uma evidência assumir uma determinada hipótese (RUSSEL; NORVIG, 2004).

Devido a elevada quantidade de tipos de incertezas, existe uma carência de ferramentas que contemple todos os formalismos existentes para modelagem. Porém, algumas *shells* possuem mais de um método para modelagem da incerteza, como é o caso da *shell* Pegasus¹ que está sendo desenvolvida pelo Grupo de Pesquisa em Inteligência Computacional Aplicada da UNESC. Esse grupo de pesquisa teve sua origem junto ao Curso de Ciência da Computação da UNESC em 2000, e tem como objetivo desenvolver pesquisas relacionando diferentes campos da inteligência computacional a áreas de conhecimento específico, promovendo assim a interdisciplinaridade entre diversas áreas de conhecimento.

Essa *shell* idealizada pelo grupo abrange inicialmente quatro módulos, cada um deles utilizando um formalismo matemático diferente para a modelagem da incerteza, são eles: Teoria de Dempster-Shafer, lógica *fuzzy*, Fatores de Certeza e Raciocínio Probabilístico.

1.1 OBJETIVO GERAL

Desenvolver a inferência de Dempster-Shafer na *shell* de modelagem da incerteza Pegasus.

¹ Referente ao projeto: "Modelagem de Incertezas Híbridas na Área de Inteligência Computacional Aplicada: Desenvolvimento de uma Shell para Construção Automatizada de Sistemas Inteligentes" aprovado pelo Programa Institucional de Bolsas de Iniciação Científica PIBIC/CNPq/UNESC, da Universidade do Extremo Sul Catarinense, regido pelo edital N 018/2008 da PROPEX (ANEXO A).

1.2 OBJETIVOS ESPECÍFICOS

O trabalho desenvolvido apresenta os seguintes objetivos específicos:

- a) compreender o processo de construção de SE;
- b) compreender o tratamento de incertezas em Sistemas Especialistas;
- c) aplicar a teoria de evidências de Dempster-Shafer;
- d) demonstrar a modelagem matemática na inferência pela Teoria de Dempster-Shafer;
- e) aplicar a modelagem matemática pela TDS em uma problemática na área da saúde;
- f) oferecer um aplicativo para modelagem do motor de inferência pela TDS.

1.3 JUSTIFICATIVA

A utilização de sistemas inteligentes pode trazer inúmeras vantagens para os seres humanos, destacando-se a alta velocidade que esses sistemas executam suas funções. Além disso, sua importância está cada vez maior, pois eles costumam ser utilizados no apoio à tomada de decisões, que é uma área estratégica dentro das organizações (REZENDE, 2005).

O desenvolvimento de SE é de ampla relevância, pois a complexidade dos problemas resolvidos por esses programas costuma superar a capacidade humana e algorítmica em calculá-los (RUSSEL; NORVIG, 2004).

As ferramentas para desenvolvimento de SE (*shells*) são muito importantes por facilitarem a criação do motor de inferência, que proporciona diversas funcionalidades, entre elas, a representação de incerteza (BITTENCOURT, 2001).

Russel e Norvig (2004) explicam que a modelagem da incerteza em SE é uma área bastante pesquisada, pois ao tratar as informações, muitas vezes elas podem estar incompletas, inexatas ou incertas podendo dificultar o processo de tomada de decisão em um domínio de aplicação.

A TDS é um dos modelos mais conhecidos para modelagem da incerteza e visa o tratamento das informações por meio de um formalismo matemático baseado em proposições lidando de forma concreta com o problema da ignorância, que corresponde ao desconhecimento de informações pelo especialista (RUSSEL; NORVIG, 2004).

Outra característica importante da TDS refere-se ao modo como novas crenças são adicionadas ao sistema. Na teoria de Bayes, a ordem com que as evidências são apresentadas pode mudar o resultado. Na TDS, o resultado não depende da ordem da apresentação das evidências e nem necessita que estas expressem certeza (UCHÔA; PANOTIM; NICOLETTI, 1997).

Devido à ausência de uma única ferramenta para modelagem de incertezas que possua estes módulos (TDS, Lógica *Fuzzy*, Fatores de Certeza e Raciocínio Probabilístico) e por facilitar o desenvolvimento de sistemas baseados em conhecimento o Grupo de Pesquisa em Inteligência Computacional Aplicada está desenvolvendo uma *shell* que conterá inicialmente esses componentes.

Assim, a partir da problemática apresentada e a necessidade de desenvolvimento do módulo da TDS para inferência na *shell* Pegasus, proporciona-se neste trabalho o estudo da utilização da teoria de Dempster-Shafer na área de lombalgia a qual oferece potencial para modelagem pela TDS e apresenta diversos trabalhos

voltados a modelagem da incerteza por aleatoriedade (GOULART, 2007; GOULARTE, 2002; SCUSSEL, 2001; VALDATI, 2008).

1.4 ESTRUTURA DO TRABALHO

O trabalho é composto de seis capítulos excetuando-se a conclusão. No capítulo inicial procurou-se descrever os objetivos, introdução e justificativa.

O Capítulo 2 apresenta uma breve descrição sobre o que vem a ser a incerteza em sistemas especialistas e algumas das técnicas para a modelagem da incerteza.

No Capítulo 3 são descritas as principais características da TDS, como o domínio do problema e as fórmulas envolvidas no cálculo dos intervalos de crença e plausibilidade².

No Capítulo 4 são apresentados os trabalhos correlatos que utilizam conceitos da TDS para realização de alguma tarefa, como aplicações e ferramentas.

O Capítulo 5 apresenta a metodologia de desenvolvimento do módulo que utiliza o formalismo da TDS na *shell* Pegasus, além dos resultados obtidos e a modelagem do motor de inferência.

Finalizando são apontadas as conclusões e recomendações para trabalhos futuros.

² A plausibilidade de uma proposição está relacionada com a possibilidade de se acreditar na proposição (LUGER, 2004).

2 MODELAGEM DA INCERTEZA

Ao se utilizar um sistema especialista costuma-se observar que o conhecimento pode estar inconsistente gerando conclusões conflitantes, ou ainda incompleto, sem as informações necessárias para se chegar a uma conclusão adequada (REZENDE, 2005).

Segundo Russel e Norvig (2004) são muitos os tipos de incerteza e para cada um existe pelo menos uma técnica que pode ser utilizada para sua modelagem. As técnicas mais conhecidas para lidar com o conhecimento incerto são baseadas nos seguintes formalismos matemáticos: Teorema de Bayes, Lógica *Fuzzy*, Fatores de Certeza e TDS.

2.1 TEOREMA DE BAYES

O Teorema de Bayes, também conhecido como modelo probabilista, é base para a inferência probabilística em diversos sistemas inteligentes desenvolvidos ao longo dos anos. Permite que probabilidades desconhecidas sejam calculadas a partir de probabilidades conhecidas (PEARL, 1988).

Esse formalismo é utilizado para a modelagem da incerteza por aleatoriedade³, podendo ser utilizado, por exemplo, na previsão do tempo, onde é calculada a probabilidade de um determinado evento climático ocorrer (COSTA; SIMÕES, 2004).

³ Esse tipo de incerteza pode ser definido como parte de algo inicialmente desconhecido, referindo-se aos eventos aleatórios que podem ser verificados por meio de cálculos probabilísticos, como por exemplo, no lançamento de uma moeda: “qual a chance de sair cara ou coroa?” (COSTA; SIMÕES, 2004, RUSSEL; NORVIG, 2004).

Para entender sua utilização algumas definições relevantes devem ser apresentadas, entre elas a de probabilidade *a priori* e *a posteriori*. A probabilidade *a priori*, também chamada de incondicional, é o grau de crença em uma determinada proposição na ausência de maiores informações, sendo simbolizada por $\Pr(\text{evento})$ (LUGER, 2004; RUSSEL; NORVIG, 2004).

Por exemplo, se a probabilidade *a priori* afirmar que um paciente está com gripe é 0.6, então:

$$\Pr(\text{Gripe} = \text{verdadeiro}) = 0.6 \text{ ou } \Pr(\text{Gripe}) = 0.6$$

Probabilidade *a posteriori* de um evento, também conhecida como condicional, é a probabilidade de um acontecimento dada alguma evidência, sendo representada por $\Pr(\text{evento} \mid \text{evidência})$. Por exemplo, $\Pr(\text{gripe} \mid \text{febre}) = 0.9$ mostra que, se um paciente estiver com febre a probabilidade dele estar gripado é de 0.9.

Russel e Norvig (2004) descrevem que com base nessas probabilidades Bayes chegou ao seguinte teorema:

$$\Pr(A|B) = \frac{\Pr(B|A) \Pr(A)}{\Pr(B)} \quad (1)$$

O raciocínio probabilístico de Bayes, devido à ampla fundamentação matemática baseada em probabilidades condicionais, tem sido utilizado desde a década de 60 principalmente no diagnóstico médico, pois pode auxiliar o trabalho desses profissionais na tomada de decisões (RUSSEL; NORVIG, 2004).

Russel e Norvig (2004) destacam ainda que na década de 70 e começo de 80, existiam diversas dificuldades para o uso desse formalismo. A principal era a ausência de uma teoria para representar informações de independência condicional⁴, o que só foi possível com a descoberta de redes bayesianas.

⁴ Ao derivar um método para construção de redes bayesianas leva-se em consideração que um nó é condicionalmente independente de seus predecessores, dados seus pais (RUSSEL; NORVIG, 2004).

Uma rede bayesiana é um grafo orientado no qual cada nó possui informações sobre probabilidades quantitativas. As redes permitem diminuir a complexidade que um problema real pode trazer e oferecem um modelo computacional, focando a busca em grupos menores de evidências e eventos, e dividindo o raciocínio em pequenos conjuntos para facilitar a modelagem da incerteza (LUGER, 2004; RUSSEL; NORVIG, 2004).

Deve-se ressaltar que a utilização dessa técnica é interessante apenas quando se trata de incerteza por aleatoriedade, por esse motivo a literatura apresenta variados tipos de formalismos.

2.2 LÓGICA FUZZY

Em 1965 um professor da Universidade da Califórnia (localizada em Berkeley) chamado Lotfi Zadeh, publicou em seu artigo *Fuzzy Sets*, uma idéia de conjuntos *fuzzy*, estabelecendo os fundamentos matemáticos da teoria. Assim, a lógica *fuzzy* ficou conhecida com esse nome devido ao trabalho posterior de Zadeh, *Outline of a new approach to the analysis of complex systems and decision processes*, publicado em 1973 (COX, 2005).

Diferente da lógica bayesiana, a lógica *fuzzy*, conhecida também como lógica difusa, é utilizada para a modelagem da incerteza por imprecisão⁵, que apresenta um tipo de informação que não possui seus limites precisamente definidos, como no exemplo citado por Russel e Norvig (2004) que considera que uma pessoa com 1.78m de altura pode ser alta para alguns, mas baixa para outros.

⁵ Esse tipo de incerteza refere-se a conjuntos vagos, ou seja, “um evento pode ser ‘uma espécie de’ verdadeiro” (RUSSEL; NORVIG, 2004).

A representação *fuzzy* de conhecimento pode ser feita por meio de variáveis lingüísticas que são utilizadas para representar um conceito em um determinado problema, admitindo apenas expressões como: frio, grande, alto, entre outras. Assim, cada conjunto *fuzzy*⁶ é associado a um termo lingüístico que classifica um valor impreciso (REZENDE, 2005).

Rezende (2005) ainda destaca que um conjunto *fuzzy* é caracterizado por uma função de pertinência, que geralmente é representada em um gráfico, denominado diagrama de *Hassi-Euler* (H-E), conforme ilustra a Figura 1, que apresenta como uma temperatura pode pertencer a mais de um conjunto. Com uma temperatura de 260 °C, pode-se observar que ela é considerada tanto alta, quanto muito alta, apresentando graus de pertinência diferentes. Neste exemplo, o grau de pertinência à temperatura alta é de 0.4, à temperatura muito alta é de 0.6.




Figura 1. Diferentes variáveis lingüísticas para a variável temperatura
Fonte: CALILI, R. (2005)

Entre as aplicações para a lógica *fuzzy*, estão os Sistemas de Apoio à Decisão⁷ (SAD), algoritmos para aproximação de funções e principalmente na área de controle onde os engenheiros possuem uma ferramenta eficiente para tratar a imprecisão de medidas (LUGER, 2004; REZENDE, 2005).

⁶ Os conjuntos *fuzzy* são diferentes dos conjuntos da lógica tradicional, pois um elemento pode pertencer a mais de um conjunto ao mesmo tempo (LUGER, 2004).

⁷ Os SAD são sistemas que processam grande quantidade de informação imprecisa e qualitativa, sendo usados principalmente por gerentes de operações, e por esse motivo modelos de inferência *fuzzy* são bastante utilizados (REZENDE, 2005).

Algoritmos para aproximação de funções não-lineares geralmente fazem parte de sistemas mais complexos de modelagem ou de controle, que efetuam cálculos de difícil resolução. Por esse motivo são necessários módulos de lógica *fuzzy* com capacidade de aproximar o comportamento dessas funções por meio de dados conhecidos.

Na área de controle de processos podem ser citadas diversas aplicações onde se encontram dificuldades na automatização. Os problemas ocorrem devido ao comportamento variante do tempo, os níveis de ruído, a baixa qualidade das medidas disponíveis, entre outros.

2.3 TEORIA DOS FATORES DE CERTEZA

O modelo dos Fatores de Certeza foi desenvolvido durante a construção do sistema especialista MYCIN⁸ com a finalidade de auxiliar a decisão de especialistas médicos. Foi observado durante seu desenvolvimento que a experiência do especialista pode ser utilizada para obtenção de explicações ou até mesmo para a sugestão de um caminho para resolução de um determinado problema (BUCHANAN; SHORTLIFFE, 1984).

O MYCIN representa uma aplicação clássica muito citada na literatura ao utilizar a técnica dos Fatores de Certeza para dar prioridade às regras a serem tentadas e determinar pontos de corte para que objetivos não sejam mais explorados (BUCHANAN; SHORTLIFFE, 1984).

⁸ Sistema especialista desenvolvido pelo grupo de Edward H. Shortliffe em 1974 na Universidade de Stanford (EUA), com o objetivo de diagnosticar doenças infecciosas e recomendar antibióticos em casos de bacteremia ou meningite (BUCHANAN; SHORTLIFFE, 1984).

Ao contrário da lógica *fuzzy*, a teoria dos Fatores de Certeza, também conhecida como teoria das certezas de *Stanford*⁹, utiliza um único valor numérico para quantificar a incerteza, denominado Fator de Certeza (FC), que indica o grau de certeza de uma regra ou afirmação (COSTA; SIMÕES, 2004).

Costa e Simões (2004) descrevem ainda que o FC é dividido em duas partes, a Medida de Crença (MC) e a Medida de Descrença (MD). A MC representa a confiança em uma afirmação ao ocorrer uma evidência e a MD mostra o grau de descrença na mesma afirmação com a ocorrência da evidência.

Por exemplo, se um especialista humano encontrar uma $MC = 0.7$ para determinada afirmação e não possuir conhecimento suficiente para afirmar que a relação seja falsa, ele pode atribuir para a mesma afirmação uma $MD = 0$.

Percebe-se assim que, nessa teoria a soma da certeza em uma relação com a confiança contra a mesma relação não necessariamente resulta em 1, sendo assim diferente da teoria de Bayes, onde essa soma sempre deverá ser 1 (LUGER, 2004).

Conforme descrito por Luger (2004) o FC pode ser calculado como:

$$FC(H | E) = MC(H | E) - MD(H | E) \quad (2)$$

Quanto mais próximo estiver o FC de 1, maior é a certeza de uma hipótese; da mesma forma, quanto mais próximo de -1, maior é a crença contra a hipótese; e quando for próximo de 0 existem poucas evidências ou as confianças a favor e contra a hipótese estão balanceadas.

Os Fatores de Certeza são utilizados em diversos sistemas, sendo geralmente encontrados em sistemas especialistas baseados em regras para refletir a confiança na credibilidade de cada regra. Se vários especialistas utilizam uma mesma base de regras eles devem concordar com os mesmos FC para cada regra. A partir da

⁹ O nome *Stanford* é referente à universidade em que foi desenvolvida a teoria dos Fatores de Certeza (BUCHANAN; SHORTLIFFE, 1984).

associação entre as regras e seus FC é possível uma otimização no desempenho do sistema por meio de simples ajustes nas medidas de crença (LUGER, 2004).

Luger (2004) ainda descreve que essa teoria é muitas vezes criticada por ser extremamente experimental e não possuir uma fundamentação matemática tão ampla como a teoria das probabilidades. Porém ela permite que sistemas especialistas combinem as confianças nas afirmações (MC e MD) conforme vão se aprofundando no problema. Seus modelos de resolução do problema são experimentais da mesma forma que especialistas humanos chegam a resultados aproximados com a utilização de heurísticas¹⁰.

Buchanan e Shortliffe (1984) explicam que os Fatores de Certeza proporcionam uma maneira prática de lidar com a quantificação de graus de crença. E concluem que os valores dados por especialistas para quantificar os graus de crença em uma determinada decisão são valores aproximados referentes ao conhecimento que eles possuem sobre a probabilidade de acontecimento dos eventos.

2.4 TEORIA DE DEMPSTER-SHAFER

Dempster (1968 apud RUSSEL; NORVIG, 2004) propôs em 1968, em sua pesquisa publicada no *Journal of the Royal Statistical Society*, uma teoria genérica da incerteza *versus* ignorância¹¹ com a finalidade de tentar complementar a teoria clássica da probabilidade na representação do raciocínio humano. Shafer (1976 apud RUSSEL; NORVIG, 2004) ampliou a teoria que acabou ficando conhecida como Teoria da Evidência de Dempster-Shafer.

¹⁰ Heurísticas são estratégias para a busca seletiva de uma parte de um problema, baseadas em regras de julgamento (LUGER, 2004).

¹¹ A ignorância refere-se principalmente às limitações do conhecimento humano e às limitações inerentes às regras heurísticas (LUGER, 2004).

A TDS modela a incerteza por ignorância e diferencia-se dos fatores de certeza e da lógica bayesiana, ao utilizar graus de crença¹², com intervalos de probabilidade, para representar o conhecimento incerto. Assim, ao contrário de calcular a probabilidade de uma proposição, a TDS calcula a chance de uma evidência assumir uma determinada hipótese (RUSSEL; NORVIG, 2004).

Esse problema pode ser exemplificado com o lançamento de uma moeda. Se a moeda for imparcial a probabilidade de ser cara ou coroa é de 50%, porém, se a moeda for viciada, a única probabilidade possível com a utilização da lógica bayesiana, ainda seria 50%, baseando-se na inexistência de eventos anteriores. Nesse caso observa-se a vantagem de uma técnica complementar ao modelo probabilista para modelagem da incerteza, por meio da TDS, principalmente por suportar o uso de probabilidades subjetivas no raciocínio. Assim, passa a ser possível levar em consideração a crença do expectador no momento do lançamento da moeda, baseada em experiências anteriores ou até mesmo por sua relação com a pessoa que irá lançar a moeda (LUGER, 2004; RUSSEL; NORVIG, 2004).

Russel e Norvig (2004) ainda explicam que esse é um dos modelos mais conhecidos para modelagem da incerteza por ignorância, visando o tratamento das informações por meio de um formalismo matemático baseado em proposições e que lida de forma concreta com o problema da ignorância.

Uma característica importante da TDS diz respeito ao modo como novas evidências são adicionadas ao sistema. Na teoria bayesiana a ordem com que as evidências são apresentadas pode afetar o resultado, na TDS o resultado não depende da ordem da apresentação das evidências e nem necessita que estas expressem certeza. Na prática a utilização da TDS cria descrições de raciocínio mais modestas que na lógica

¹² O grau de crença indica a certeza nas evidências de um conjunto de hipóteses (LUGER, 2004).

bayesiana, porém a grande vantagem está na sua semelhança com a forma humana de pensar (UCHÔA; PANONTIN; NICOLETTI, 1997).

Pode-se perceber que a utilização da TDS é muito interessante, pois seu formalismo matemático indica a capacidade de modelar a incerteza em diversos problemas nos quais outras teorias não se adaptam de maneira adequada, como nos formalismos MSDF (*Multi-Sensor Data Fusion*) em domínios de aplicações militares (WU, 2003).

2.5 COMPARATIVO DAS TEORIAS

Cada teoria apresentada nesse capítulo possui suas peculiaridades. O teorema de Bayes foi desenvolvido pelo clérigo Thomas Bayes em 1763. Sua teoria é capaz de modelar a incerteza por aleatoriedade sendo muito utilizada em SE.

A lógica *fuzzy* foi descrita pela primeira vez na pesquisa de Lofti Zadeh, em 1965. Seu trabalho apresentou uma das teorias mais conhecidas para modelagem da incerteza por imprecisão (COX, 2005).

O modelo de Fatores de Certeza foi desenvolvido durante a criação do MYCIN pela equipe de Edward Shortliffe em 1965. A teoria utiliza a confiança dos especialistas para modelar a incerteza nos SE (BUCHANAN; SHORTLIFFE, 1984).

A TDS iniciou com o trabalho de Arthur Dempster em 1968 e foi ampliado por Glenn Shafer em 1976. Os formalismos da TDS são utilizados pelos SE para modelagem da incerteza por ignorância (RUSSEL; NORVIG, 2004).

A Tabela 1 apresenta um resumo das teorias para modelagem da incerteza descritas nesse capítulo.

Tabela 1. Comparação entre os formalismos para a modelagem da incerteza

| Teoria | Tipo de Incerteza modelada | Criador | Data |
|--------------------|-----------------------------------|----------------------|-------------|
| Teorema de Bayes | Aleatoriedade | Thomas Bayes | 1763 |
| Lógica Fuzzy | Imprecisão | Lofti Zadeh | 1965 |
| Fatores de Certeza | Confiança | Edward H. Shortliffe | 1976 |
| TDS | Ignorância | Glenn Shafer | 1976 |

Como pode-se observar são diversas as teorias para modelagem da incerteza, sendo que neste trabalho o principal destaque é a TDS. Assim, no Capítulo 3 são apresentados os seus fundamentos matemáticos aplicados durante o processo de inferência.

3 TEORIA DA EVIDÊNCIA DE DEMPSTER-SHAFER

O capítulo anterior apresentou a TDS como uma técnica de modelagem da incerteza em sistemas especialistas, que permite a distinção entre ignorância e aleatoriedade, pois conforme já apresentado, são conceitos diferentes e devem ser tratados de maneira diferente (RUSSEL; NORVIG, 2004).

Russel e Norvig (2004) descrevem ainda que ao desconhecer o valor específico de uma variável não significa que a mesma esteja sujeita a incerteza. Nesse sentido, com a teoria clássica da probabilidade, a crença e a descrença são funções opostas. Por exemplo, se A, B e C são os únicos eventos em um universo (S) conhecendo-se que:

$$\Pr(A) = 0.3$$

$$\Pr(B) = 0.6$$

Assim, com a utilização da teoria clássica da probabilidade o único valor possível para $\Pr(C)$ é 0.1, sendo que:

$$\Pr(S) = \Pr(A) + \Pr(B) + \Pr(C) = 1$$

Por outro lado, esta afirmação pode não representar o raciocínio humano de forma adequada, pois a probabilidade de C pode não estar relacionada com a certeza da probabilidade. O fato pode ser a ignorância da probabilidade do acontecimento do evento C. Assim, conhecer as probabilidades de A e B não significa que se pode também ter conhecimento da probabilidade de C (BADIRU; CHEUNG, 2002).

Desse modo, como apresentado no capítulo anterior, em uma tentativa de superar algumas deficiências da teoria clássica da probabilidade na representação do raciocínio humano, Dempster propôs uma teoria que mais tarde foi ampliada por Shafer

ficando conhecida como Teoria da Evidência de Dempster-Shafer (DEMPSTER, 1968 apud RUSSEL; NORVIG, 2004; SHAFER, 1976 apud RUSSEL; NORVIG, 2004).

Essa teoria baseia-se na atribuição de probabilidades a todos os subconjuntos de um universo de discurso, e não apenas aos membros individuais, como na teoria clássica da probabilidade. O formalismo da TDS suporta ainda o uso de probabilidades subjetivas no raciocínio, que muitas vezes refletem melhor o raciocínio de um especialista humano (BADIRU; CHEUNG, 2002; LUGER, 2004).

Diferente das abordagens probabilísticas, que usam apenas um valor para medir uma situação muitas vezes complexa, a TDS é uma alternativa que considera conjuntos de proposições relacionadas a um intervalo de crença e plausibilidade (LUGER, 2004).

Nesse contexto, os itens a seguir descrevem o formalismo matemático da TDS e seus principais conceitos como o domínio do problema, a função de crença, a plausibilidade e a regra de Dempster.

3.1 DOMÍNIO DO PROBLEMA

O domínio do problema (Θ) é o universo de discurso, também conhecido como *frame* de discernimento, e representa o conjunto das hipóteses primitivas denominadas *singletons*¹³ (CARVALHO, 2001; UCHÔA; PANOTIM; NICOLETTI, 1997).

Exemplo 1: Como exemplo para entendimento sobre o universo de discurso será utilizado um caso de diagnóstico de problemas em computadores.

¹³ As hipóteses primitivas são conhecidas dessa maneira por serem conjuntos individuais (CARVALHO, 2001; UCHÔA; PANOTIM; NICOLETTI, 1997).

Supondo que um computador desliga involuntariamente durante sua utilização e que isso ocorra freqüentemente, esse acontecimento pode ser resultante de qualquer um dos seguintes fatores: vírus {v}, rede elétrica inconstante {e}, mau funcionamento de *hardware* {h} e ausência de aterramento {a}. Embora possam existir diversas hipóteses possíveis, para simplificar a situação serão utilizadas apenas essas quatro.

Nesse exemplo:

$$\Theta = \{v,e,h,a\}$$

Na TDS Θ é exaustivo, contendo todas as possíveis hipóteses primitivas. Deve-se levar em consideração ainda que as *singletons* no domínio do problema são mutuamente exclusivas¹⁴.

Supondo novas evidências consideradas pelo especialista que mostram um problema de travamento, definido como o conjunto {v,e,a}, ou então um diagnóstico de lentidão, definido como o conjunto {v,e,h}, se o técnico especialista observar uma evidência que confirma as hipóteses do diagnóstico de travamento, ele irá atribuir um valor para crença ao conjunto {v,e,a} proporcional ao grau observado durante a confirmação da evidência.

Outras evidências podem ainda excluir a possibilidade de mau funcionamento de hardware {h} do diagnóstico e confirmar a existência de aterramento {a}. Essas evidências podem ser tratadas de uma maneira que confirme o resto do conjunto de hipóteses, e assim, o conjunto {v,e}.

Os subconjuntos de hipóteses de Θ podem ser analisados como se fossem novas hipóteses, e são formados pela disjunção de seus elementos, pelo fato das *singletons* serem mutuamente exclusivas. O conjunto Θ origina 2^{Θ} possíveis hipóteses,

¹⁴ Um evento A é dito como mutuamente exclusivo quando sua ocorrência elimina a possibilidade de ocorrência de um evento B. Descrevendo matematicamente tem-se: $A \cap B = \emptyset$ (JAMES, 1981).

assim baseando-se no exemplo anterior $\Theta = \{v,e,h,a\}$, tem-se 4 *singletons*, originando 16 hipóteses ($2^\Theta = 2^4 = 16$), conforme ilustra a Figura 2.




Figura 2. Conjunto de todas as hipóteses possíveis a partir de $\Theta = \{v,e,h,a\}$
 Fonte: Adaptado de UCHÔA, J.; PANOTIM, S.; NICOLETTI, M. (1997)

O conhecimento sobre o domínio do problema é de extrema importância para o entendimento dos demais formalismos matemáticos da TDS, como a atribuição básica de probabilidade.

3.2 CONCEITOS BÁSICOS

A TDS associa à crença um valor numérico que varia entre 0 e 1 para demonstrar a crença em uma determinada hipótese em relação a uma evidência. A relevância das evidências para cada elemento de 2^Θ é representada por uma função chamada atribuição de probabilidade básica (*bpa*¹⁵) (CARVALHO, 2001; UCHÔA; PANOTIM; NICOLETTI, 1997).

A soma de todas as atribuições feitas aos subconjuntos de Θ deve ser igual a 1. Aos conjuntos vazios o número 0 deve ser atribuído, sendo que esses conjuntos são caracterizados por representar uma hipótese falsa (SENTZ; FERSON, 2002).

¹⁵ *bpa* provém do inglês *basic probability assignment*. Essa função também é conhecida por função de massa (UCHÔA; PANOTIM; NICOLETTI, 1997).

A *bpa* é notada por m , sendo o valor de $m(A)$ a medida de uma parte da crença total, que é atribuída à A , onde A é um elemento de 2^Θ e a crença total é igual a 1. Formalmente, sendo Θ um domínio de problema, então:

$$m: 2^\Theta \rightarrow [0,1]$$

Os formalismos a seguir descrevem matematicamente a *bpa*:

- a) $m(\emptyset) = 0$: a *bpa* atribuída ao conjunto de hipóteses vazio deve ser 0;
- b) $m(A) \geq 0, \forall A \in 2^\Theta$: os valores atribuídos às *bpa* são todos maiores ou iguais a 0;

Outra característica importante é que a soma de todas as *bpa* deve resultar 1, conforme o formalismo a seguir:

$$\sum_{A \in 2^\Theta} m(A) = 1 \quad (3)$$

Ao atribuir as probabilidades básicas aos subconjuntos de Θ pode ser que ainda exista alguma crença não atribuída. Dessa forma, se $m(A) = x$ e m não atribui crença a nenhum outro subconjunto de Θ , então $m(\Theta) = 1 - x$. Ou seja, o resto da crença é atribuído a Θ (CARVALHO, 2001; UCHÔA; PANOTIM; NICOLETTI, 1997).

Exemplo 2: levando em consideração o exemplo 1 apresentado no item 3.1 é descrita uma possível atribuição de probabilidade básica.

Supondo que um especialista encontre uma evidência que descreve um problema de vírus de computador, e que isso sugere a hipótese $\{v\}$ em 0.2, tem-se assim uma primeira crença:

$$m(\{v\}) = 0.2$$

O mesmo especialista pode verificar outras evidências como um problema na rede elétrica, sugerindo a hipótese $\{e\}$ com um nível de suporte em 0.3, um mau funcionamento no hardware, onde a hipótese $\{h\}$ recebe 0.1, e um problema de

desligamento desconhecido, atribuindo 0.4 ao conjunto de hipóteses $\{v,e\}$. Assim, descrevendo matematicamente tem-se:

$$m(\{e\}) = 0.3$$

$$m(\{h\}) = 0.1$$

$$m(\{v,e\}) = 0.4$$

Todas as outras hipóteses que não apresentam nenhuma evidência devem receber 0. Formalmente tem-se:

$$m(A) = 0, \text{ para } \forall A \in 2^\Theta, A \neq \{v\}, A \neq \{e\}, A \neq \{h\}, A \neq \{v,e\}$$

Exemplificando esta última afirmação tem-se:

$$m(\{v,e,h\}) = 0$$

$$m(\{v,e,a\}) = 0$$

$$m(\{v,h\}) = 0$$

Pode-se perceber assim que a soma das probabilidades atribuídas é igual a 1, conforme a fórmula 3:

$$m(\{v\}) + m(\{e\}) + m(\{h\}) + m(\{v,e\}) = 0.2 + 0.3 + 0.1 + 0.4 = 1$$

Exemplo 3: ainda com relação ao exemplo 1, supondo que não exista evidência com relação a qualquer diagnóstico em um computador com problema de desligamento involuntário. A função de *bpa* atribui 1 a $\Theta = \{v,e,h,a\}$ e 0 aos outros subconjuntos de Θ . Nesse exemplo:

$$m(\Theta) = m(\{v,e,h,a\}) = 1$$

$$m(A) = 0, \text{ para } \forall A \in 2^\Theta, A \neq \Theta$$

O modelo bayesiano tentaria representar a ignorância atribuindo 0.25 a cada hipótese primitiva, levando em consideração a inexistência de informações *a priori*. Ou seja:

$$m(\{v\}) = m(\{e\}) = m(\{h\}) = m(\{a\}) = 0.25$$

Pode-se perceber que essa atribuição implica em mais informações do que realmente existe. A TDS considera a evidência contra uma hipótese apenas quando a evidência suporta a negação da hipótese.

Essa última afirmação pode ser exemplificada supondo uma nova evidência que suporta a existência de aterramento $\{a\}$, com um grau 0.9. Essa suposição corresponde à negação da hipótese de $\{a\}$, confirmando assim a evidência de $\{v,e,h\}$ em 0.9. Assim:

$$m(\{v,e,h\}) = 0.9$$

$$m(\Theta) = 0.1$$

$$m(A) = 0, \text{ para } \forall A \in 2^\Theta, A \neq \{v,e,h\}, A \neq \Theta$$

Como pode-se perceber foi atribuído o valor 0.1 à $m(\Theta)$ pois não existe evidência que suporte nenhuma outra hipótese.

Os conceitos básicos vistos neste item são relevantes para o entendimento da utilização da regra de Dempster para a combinação de evidências e compreensão da relação entre a *bpa* e as medidas de crença e plausibilidade.

3.3 FUNÇÃO DE CRENÇA E PLAUSIBILIDADE

A medida de crença, denominada *bel*, representa um valor que varia entre 0 e 1, indicando que não existe nenhuma evidência relacionada a um conjunto de proposições (0) ou que tem-se certeza absoluta (1) (LUGER, 2004).

Costa e Simões (2004) representam a função de crença como:

$$bel: 2^\Theta \rightarrow [0,1]$$

A crença em uma determinada proposição A é igual a soma das crenças atribuídas pela função de *bpa* a cada um de seus subconjuntos, dessa forma:

$$bel(A) = \sum_{B \subseteq A} m(B) \quad (4)$$

Como descrito por Luger (2004), a plausibilidade (pl) de uma proposição varia de 0 a 1. Assim, se existir a evidência de que uma proposição (p) for falsa ($\neg(p)$), então a crença nela ($bel(\neg(p))$) será igual a 1 e a plausibilidade ($pl(p)$) será 0, de acordo com a fórmula a seguir:

$$pl(p) = 1 - bel(\neg(p)) \quad (5)$$

Costa e Simões (2004) utilizam a fórmula da plausibilidade para conseguir uma outra expressão:

$$pl(A) = \sum_{B \subseteq \emptyset} m(B) - \sum_{B \subseteq \neg A} m(B) \quad (6)$$

Assim:

$$pl(A) = \sum_{B \cap A = \emptyset} m(B) \quad (7)$$

Esta última fórmula apresenta uma alternativa para se calcular a plausibilidade. Durante sua aplicação é necessário efetuar a intersecção das hipóteses e somar todas as bpa cuja intersecção não resulte em um conjunto vazio.

Com os valores de $bel(A)$ e $pl(A)$, a TDS define um intervalo $[bel(A), pl(A)]$ para representar a crença em um determinado conjunto de hipóteses (COSTA; SIMÕES, 2004; UCHÔA; PANOTIM; NICOLETTI, 1997).

Sendo $\Theta = \{v, e, h, a\}$ e $A = \{v\}$, $B = \{e\}$ e $C = \{v, e\}$, como no Exemplo 2, exemplifica-se como ficariam os intervalos de crença baseando-se nas fórmulas 4 e 7. Para calcular a crença na hipótese do conjunto A ($bel(A)$) deve-se somar todas as bpa dos conjuntos de hipóteses contidos ou iguais a (A) e para calcular a plausibilidade na hipótese do conjunto A ($pl(A)$) deve-se somar todas as bpa dos conjuntos de hipóteses

cuja intersecção com (A) não resulte em um conjunto vazio. Assim, o intervalo $[bel(A), pl(A)]$ resulta em:

$$[bel(A), pl(A)] = [m(\{v\}), m(\{v\}) + m(\{v,e\})] = [0.2, 0.2 + 0.4] = [0.2, 0.6]$$

Os demais intervalos são calculados da mesma forma. Assim, para os conjunto B e C tem-se os seguintes cálculos:

$$[bel(B), pl(B)] = [m(\{e\}), m(\{e\}) + m(\{v,e\})] = [0.3, 0.3 + 0.4] = [0.3, 0.7]$$

$$[bel(C), pl(C)] = [m(\{v,e\}) + m(\{v\}) + m(\{e\}), m(\{v,e\}) + m(\{v\}) + m(\{e\})]$$

$$[bel(C), pl(C)] = [0.4 + 0.2 + 0.3, 0.4 + 0.2 + 0.3] = [0.9, 0.9]$$

Estes resultados representam o limite mínimo e máximo em que o especialista pode confiar para tomar sua decisão, assim para cada um dos conjuntos A, B e C tem-se:

$$a) [bel(A), pl(A)] = [bel(\{v\}), pl(\{v\})] = [0.2, 0.6];$$

$$b) [bel(B), pl(B)] = [bel(\{e\}), pl(\{e\})] = [0.3, 0.7];$$

$$c) [bel(C), pl(C)] = [bel(\{v,e\}), pl(\{v,e\})] = [0.9, 0.9].$$

Deste modo, a partir dos conceitos vistos sobre crença e plausibilidade é possível apresentar uma explicação mais detalhada sobre a aplicação da regra de Dempster, levando em consideração que a utilização desta só é necessária quando existem diferentes medidas de crença para um mesmo universo de proposições (Θ).

3.4 A REGRA DE DEMPSTER

Supondo a existência de duas hipóteses conflitantes, se elas não possuem nenhuma informação relacionada, elas têm a medida de crença e plausibilidade indefinidas, variando entre 0 e 1. Com o acúmulo de informações sobre as hipóteses,

esse intervalo deve diminuir e as hipóteses podem ser consideradas confiáveis (LUGER, 2004).

Esse problema pode ser exemplificado com o lançamento de um dado. Se o dado for imparcial a probabilidade de sair um dos números é de 1/6. Porém, se o dado for viciado, a distribuição de probabilidades com a utilização dos conceitos de Bayes ainda seria de 1/6. Com base nessa situação, pode-se verificar a utilidade da TDS em casos quando é importante a tomada de decisão com base na quantidade de evidências coletadas sobre uma determinada hipótese.

Se existissem as mesmas hipóteses em um domínio bayesiano sem evidência alguma, as probabilidades seriam distribuídas igualmente entre as hipóteses. Assim, pode-se ter a mesma medida de probabilidade não importando a quantidade de informações.

Ao aplicar a regra de Dempster, são necessários os graus de crença de uma determinada proposição a partir das probabilidades de uma outra proposição, levando em consideração que essas evidências possuam independência *a priori* (LUGER, 2004; YAGER; KACPRZYK; FEDRIZZI, 1994).

Luger (2004) e ainda descreve que o formalismo matemático da regra de Dempster supõe um conjunto de hipóteses (Θ), onde os elementos de Θ são mutuamente exclusivos. O objetivo da regra é atribuir um valor de crença (m) para cada subconjunto (Z) de Θ . Nesse sentido deve-se observar que nem toda evidência suporta algum elemento do conjunto principal, mas que as evidências dão suporte, quase sempre, aos vários subconjuntos de Θ . Para encontrar a medida de crença, os conjuntos de hipóteses são tratados diretamente, tendo-se:

$$m_n(Z) = \frac{\sum_{X \cap Y = Z} m_{n-2}(X) m_{n-1}(Y)}{1 - \sum_{X \cap Y = \phi} m_{n-2}(X) m_{n-1}(Y)} \quad (8)$$

Ao aplicar esta fórmula, a crença combinada ($m_n(Z)$) recebe o valor da soma dos produtos entre $m_{n-2}(X)$ e $m_{n-1}(Y)$, que representam as crenças dos especialistas, quando a intersecção entre X e Y resulte Z . Deve-se levar em consideração que X , Y e Z são conjuntos de hipóteses pertencentes à Θ e n é o número da fonte das informações, que pode ser um especialista ou uma outra crença combinada. Assim, se n for 3 então $m_{n-2}(X)$ e $m_{n-1}(Y)$ serão respectivamente as crenças do primeiro e do segundo especialista.

O denominador da fórmula só será utilizado se existir alguma intersecção entre X e Y que resulte em um conjunto vazio, se isso ocorrer então todas as crenças combinadas devem ser divididas pela soma dos produtos entre $m_{n-2}(X)$ e $m_{n-1}(Y)$ subtraídos de 1. Se durante a utilização da regra não existir nenhum conjunto $X \cap Y$ que seja vazio o denominador será sempre igual a 1.

Conforme Luger (2004) descreve se durante a utilização da regra uma grande medida de crença for atribuída a um conjunto vazio, isso indica que existem evidências conflitantes dentro de um mesmo conjunto. Deve-se observar também que evidências complexas e grandes conjuntos de hipóteses podem tornar os cálculos muito complexos.

Considerando os conceitos apresentados, essa regra será utilizada para a modelagem da incerteza por ignorância na inferência da *shell* Pegasus, que tem por objetivo aplicar diferentes técnicas da IA para o tratamento do conhecimento incerto. Assim, uma das funcionalidades das *shells* é a construção de sistemas especialistas, sendo que o próximo item aborda as principais características desses tipos de sistemas.

3.5 INFERÊNCIA PELA TEORIA DE DEMPSTER-SHAFER

Sistemas Especialistas (SE) podem ser entendidos como sistemas capazes de representar o conhecimento de um especialista humano adquirido durante seu trabalho ou estudo (FERNANDES, 2003; LUGER, 2004).

A construção de um SE acontece com a utilização do conhecimento de um especialista humano, transformando-o de tal forma que um computador possa aplicá-lo em problemas específicos (LUGER, 2004).

A estrutura geral de um SE é composta pelo Núcleo do Sistema (NS), a Base de Conhecimento (BC), a Memória de Trabalho (MT) e a Interface do Usuário, conforme ilustra a Figura 3. Deve-se destacar que nem todos os SE possuem a mesma estrutura, mas a maioria apresenta esses módulos principais (REZENDE, 2005).

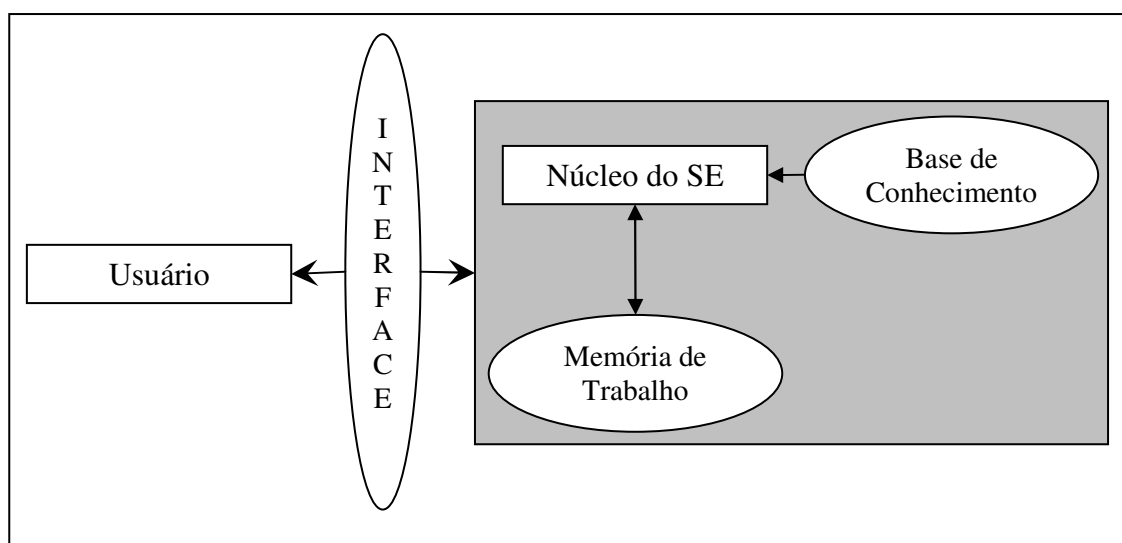


Figura 3. Estrutura geral de um SE
Fonte: Adaptado de REZENDE, S. (2005)

A Interface é o módulo responsável por simplificar a comunicação entre o usuário e o sistema. A Base de Conhecimento é um conjunto de sentenças representadas por meio de uma linguagem para representação desse conhecimento. A MT é responsável por registrar todas as respostas fornecidas pelo usuário e pelo sistema em tempo de execução com o objetivo de não permitir que ele responda uma mesma

questão mais de uma vez. O NS é dividido em duas partes principais: o Subsistema de Explicação e o Motor de Inferência (MI) (REZENDE, 2005).

O Subsistema de Explicação é a parte do sistema que fornece uma explanação do raciocínio ao usuário e o MI é um interpretador da BC, que aplica procedimentos para a solução de problemas. Ao iniciar o sistema ele busca na BC por fatos e regras e as compara com os dados fornecidos pelo usuário, sendo esse seu princípio de funcionamento (FERNANDES, 2003; REZENDE, 2005).

As principais características do MI estão relacionadas as seguintes funcionalidades: método de raciocínio, estratégia de busca e representação de incerteza (BITTENCOURT, 2001).

Os dois tipos de métodos de raciocínio mais conhecidos são: o encadeamento para frente (*forward chaining*) e o encadeamento para trás (*backward chaining*) (LUGER, 2004; RUSSEL; NORVIG, 2004).

A principal característica do encadeamento para frente é a produção de conclusões a partir das regras da BC. É um procedimento dirigido a dados, pois a inferência não é direcionada para a resolução de um problema particular. Com esse tipo de encadeamento as hipóteses são provadas a partir dos dados do problema (CARVALHO, 2001; REZENDE, 2005).

No encadeamento para trás, o MI efetua a busca a partir do objetivo, em direção aos dados fornecidos pelo problema. Nessa abordagem o raciocínio encontra as regras que poderiam produzir esse objetivo e segue de forma regressiva entre as regras até encontrar, ou não, os fatos conhecidos (LUGER, 2004).

Além do tipo de encadeamento, o MI precisa de uma estratégia de busca para conduzir a pesquisa na MT e na BC. Essas estratégias são muito estudadas em IA,

por exemplo, para a solução de problemas em diversos tipos de jogos por computador como damas e xadrez (BITTENCOURT, 2001).

Bittencourt (2001) explica que após o processo de busca, o MI possui as premissas, conhecidas como conjunto de conflito, que resolvem o problema em sua situação atual, e se esse conjunto de regras for vazio, a inferência é finalizada, caso contrário, é preciso selecionar as regras que serão executadas e em qual ordem.

Após a seleção e execução das regras o MI verifica novamente se existem novas informações no MCD. Dessa forma, o processo de inferência é reiniciado, como um ciclo (LUGER, 2004).

Luger (2004) afirma ainda que as informações na BC não são representadas apenas pelas regras. Existem diversas outras formas de representação, como os sistemas baseados em casos¹⁶ e sistemas especialistas baseados em modelo¹⁷.

A modelagem da incerteza, como definida anteriormente, é muito importante no processo de inferência, pois muitas vezes o conhecimento da BC não está completamente correto ou o usuário não informa os dados suficientes para uma resolução simplificada do problema (REZENDE, 2005).

3.6 EXEMPLO DE INFERÊNCIA

Será utilizado um caso de diagnóstico de problemas em computadores como exemplo para entendimento da inferência da TDS, mais especificadamente o Exemplo 1, descrito no Capítulo 3, Item 1, onde $\Theta = \{v,e,h,a\}$.

¹⁶ Nos sistemas baseados em casos a BC possui também exemplos de soluções de problemas. Durante a utilização do SE o MI verifica a possibilidade de utilização dos casos anteriores para resolução do problema. Desse modo pode-se afirmar que o sistema adquire experiência com a sua utilização (LUGER, 2004).

¹⁷ Sistemas baseados em modelos são capazes de utilizar regras heurísticas em suas BC (LUGER, 2004).

No caso hipotético, supondo que a primeira evidência considerada pelo especialista descreve um problema de travamento, e que isso sugere $\{v,e,a\}$ em 0.6, tem-se assim uma primeira crença:

$$m_1(\{v,e,a\}) = 0.6$$

Assim, como descrito por Sentz e Ferson (2002) a soma de todas as atribuições feitas aos subconjuntos de Θ deve ser igual a 1. Conforme a fórmula 3 (Capítulo 3, Item 2):

$$\sum_{A \in 2^\Theta} m(A) = 1$$

Desse modo, como não existe evidência que suporte nenhuma outra hipótese deve-se atribuir o valor 0.4 à $m_1(\Theta)$, para que a soma de todas as *bpa* seja igual a 1, desse modo:

$$m_1(\Theta) = 0.4$$

Todas as outras hipóteses que não apresentam nenhuma evidência devem receber 0. Descrevendo matematicamente tem-se:

$$m_1(A) = 0, \text{ para } \forall A \in 2^\Theta, A \neq \{v,e,a\}, A \neq \Theta$$

Assim, supondo que novos dados adquiridos pelo especialista mostrem casos de lentidão, sugerindo o conjunto $\{v,e,h\}$ com nível de suporte em 0.7, surge aqui uma nova crença:

$$m_2(\{v,e,h\}) = 0.7$$

Assim como analisado anteriormente não existem evidências que suportem outras hipóteses, portanto deve-se atribuir o valor 0.3 à $m_2(\Theta)$, desse modo:

$$m_2(\Theta) = 0.3$$

E como as demais hipóteses que não apresentam nenhuma evidência devem receber 0. Assim:

$$m_2(A) = 0, \text{ para } \forall A \in 2^\Theta, A \neq \{v,e,h\}, A \neq \Theta$$

Utilizando a regra de Dempster para combinar as duas crenças existentes, tem-se X como o conjunto dos diversos subconjuntos de Θ para os quais m_1 atribui um valor diferente de 0 e Y como o conjunto de subconjuntos de Θ para os quais m_2 atribui um valor diferente de 0. Aplicando a fórmula 8 (Capítulo 3, Item 4) pode ser definida uma crença combinada, m_3 , sobre subconjuntos Z de Θ , onde Z é o conjunto intersecção entre X e Y .

$$m_n(Z) = \frac{\sum_{X \cap Y = Z} m_{n-2}(X) m_{n-1}(Y)}{1 - \sum_{X \cap Y = \emptyset} m_{n-2}(X) m_{n-1}(Y)}$$

Se durante a utilização da regra não existir nenhum conjunto $X \cap Y$ que seja vazio o denominador será sempre igual a 1. Assim pode-se usar uma regra simplificada:

$$m_n(Z) = \sum_{X \cap Y = Z} m_{n-2}(X) m_{n-1}(Y) \quad (9)$$

A distribuição de crenças para m_3 é descrita na Tabela 2, levando em consideração que para o cálculo é necessário efetuar a multiplicação do valor da crença em m_1 com o valor de m_2 e efetuar a intersecção entre os conjuntos de hipóteses de m_1 e m_2 conforme representa a fórmula 9.

Tabela 2. Utilização da regra de Dempster na distribuição de crenças para m_3

| m_1 | m_2 | m_3 |
|------------------------|------------------------|-------------------------|
| $m_1(\{v,e,a\}) = 0.6$ | $m_2(\{v,e,h\}) = 0.7$ | $m_3(\{v,e\}) = 0.42$ |
| $m_1(\Theta) = 0.4$ | $m_2(\{v,e,h\}) = 0.7$ | $m_3(\{v,e,h\}) = 0.28$ |
| $m_1(\{v,e,a\}) = 0.6$ | $m_2(\Theta) = 0.3$ | $m_3(\{v,e,a\}) = 0.18$ |
| $m_1(\Theta) = 0.4$ | $m_2(\Theta) = 0.3$ | $m_3(\Theta) = 0.12$ |

Pode-se perceber que a soma das crenças atribuídas pela função de bpa é igual a 1, conforme a fórmula 3 (Capítulo 3, Item 2), ou seja:

$$m_3(\{v,e\}) + m_3(\{v,e,h\}) + m_3(\{v,e,a\}) + m_3(\Theta) = 0.42 + 0.28 + 0.18 + 0.12 = 1$$

Como pode-se observar na terceira coluna da Tabela 2, não existe nenhum conjunto de hipóteses vazio nas crenças combinadas (m_3). Assim, o denominador para a fórmula 8 (Capítulo 3, Item 4) é igual a 1.

Dessa forma a combinação das crenças é finalizada e os valores de $m_3(A)$ representam a crença em cada conjunto A , e com eles pode-se calcular o intervalo de crença total e a plausibilidade.

Este intervalo representa o quanto se pode acreditar nas probabilidades calculadas. Com a utilização das fórmulas 4 e 7 (Capítulo 3, Item 3) são descritos os cálculos dos intervalos:

$$bel(A) = \sum_{B \subseteq A} m(B) \qquad pl(A) = \sum_{B \cap A = \emptyset} m(B)$$

Para calcular a crença ($bel(\{v,e\})$) deve-se somar todas as *bpa* dos conjuntos de hipóteses contidos ou iguais a $\{v,e\}$ e para calcular a plausibilidade ($pl(\{v,e\})$) deve-se somar todas as *bpa* dos conjuntos de hipóteses cuja intersecção com $\{v,e\}$ não resulte em um conjunto vazio. Assim, o intervalo $[bel(\{v,e\}), pl(\{v,e\})]$ é calculado:

$$[bel(\{v,e\}), pl(\{v,e\})] = [m(\{v,e\}), m(\{v,e\}) + m(\{v,e,h\}) + m(\{v,e,a\}) + m(\Theta)]$$

$$[bel(\{v,e\}), pl(\{v,e\})] = [0.42, 0.42 + 0.28 + 0.18 + 0.12] = [0.42, 1]$$

Os demais intervalos são calculados da mesma forma. Dessa maneira, para o conjunto $\{v,e,h\}$ tem-se:

$$[bel(\{v,e,h\}), pl(\{v,e,h\})] = [m(\{v,e,h\}) + m(\{v,e\}),$$

$$m(\{v,e,h\}) + m(\{v,e,a\}) + m(\{v,e\}) + m(\Theta)]$$

$$[bel(\{v,e,h\}), pl(\{v,e,h\})] = [0.28 + 0.42, 0.28 + 0.18 + 0.42 + 0.12] = [0.7, 1]$$

Para o conjunto $\{v,e,a\}$ tem-se:

$$[bel(\{v,e,a\}), pl(\{v,e,a\})] = [m(\{v,e,a\}) + m(\{v,e\}),$$

$$m(\{v,e,h\}) + m(\{v,e,a\}) + m(\{v,e\}) + m(\Theta)]$$

$$[bel(\{v,e,a\}), pl(\{v,e,a\})] = [0.18 + 0.42, 0.28 + 0.18 + 0.42 + 0.12] = [0.6, 1]$$

Para o domínio do problema (Θ) tem-se:

$$[bel(\Theta), pl(\Theta)] = [m(\{v,e,h\}) + m(\{v,e,a\}) + m(\{v,e\}) + m(\Theta), \\ m(\{v,e,h\}) + m(\{v,e,a\}) + m(\{v,e\}) + m(\Theta)]$$

$$[bel(\Theta), pl(\Theta)] = [0.28 + 0.18 + 0.42 + 0.12, 0.28 + 0.18 + 0.42 + 0.12] = [1, 1]$$

A partir desse cálculo pode-se observar que a crença total apresenta a soma de todas as outras *bpa*, o que não ocorre conseqüentemente nos demais intervalos que representam parte do domínio do problema.

Assim, estes resultados representam o limite mínimo e máximo em que o especialista pode confiar para tomar sua decisão:

- a) Para o conjunto $\{v,e\}$: $[bel(\{v,e\}), pl(\{v,e\})] = [0.42, 1]$;
- b) Para o conjunto $\{v,e,h\}$: $[bel(\{v,e,h\}), pl(\{v,e,h\})] = [0.7, 1]$;
- c) Para o conjunto $\{v,e,a\}$: $[bel(\{v,e,a\}), pl(\{v,e,a\})] = [0.6, 1]$;
- d) Para o domínio do problema (Θ): $[bel(\Theta), pl(\Theta)] = [1, 1]$.

Deve-se levar em consideração que uma grande crença atribuída ao conjunto vazio significa que existem evidências conflitantes dentro de um mesmo conjunto de crenças m_i (LUGER, 2004).

O item a seguir descreve os limites da aplicação da TDS em alguns casos específicos.

3.7 PESO DE CONFLITO

Muitas vezes, mesmo com a possibilidade de combinação de duas funções de crença, o resultado pode não ser o desejado, apresentando-se em alguns casos contrário à intuição. O peso do conflito, notado por $con(bel_1, bel_2)$, oferece dados

primordiais sobre a combinação dessas crenças (UCHÔA; PANOTIM; NICOLETTI, 1997).

O valor desse peso pode representar tanto o conflito entre os especialistas quanto o desconhecimento deles na análise de um determinado problema e deve ser analisado sempre ao se combinar as funções de crença (CAMPOS, 2005; UCHÔA; PANOTIM; NICOLETTI, 1997).

Uchoa, Panotim e Nicoletti (1997) destacam que a análise do peso de conflito garante maior segurança nas decisões fornecendo algumas informações sobre as hipóteses e evidências. O valor dele é considerado aceitável quando é inferior a 0.6, e ao ultrapassar esse valor os resultados são altamente indesejáveis.

O peso de conflito é definido pelo logaritmo natural¹⁸, porém ele pode ser definido para qualquer logaritmo de base maior que 1:

$$con(bel_1, bel_2) = \log(\chi) \quad (10)$$

O valor de χ é definido por:

$$\chi = 1 / (1 - \kappa) \quad (11)$$

Onde κ é a soma de todas as *bpa* das ocorrências de conjuntos vazios:

$$\kappa = \sum m(\phi) \quad (12)$$

O exemplo a seguir mostra como pode ser negativa a combinação de evidências com um valor de peso de conflito superior a 0.6. Supondo que dois especialistas examinem um paciente e concordem que ele possa estar resfriado (R), gripado (G) ou com pneumonia (P). Assim:

$$\Theta = \{R, G, P\}.$$

O primeiro especialista supõe que o paciente possa estar resfriado e atribui uma probabilidade básica de 0.9 para essa evidência, assim:

¹⁸ São logaritmos que tem como base o *e* neperiano (STEWART, 2006).

$$m_1(\{R\}) = 0.9$$

O mesmo especialista supõe ainda que o paciente possa estar com pneumonia e atribui uma probabilidade de 0.1 a essa evidência, desse modo:

$$m_1(\{P\}) = 0.1$$

Como se pode perceber, esse médico atribuiu toda a sua crença em duas hipóteses diferentes, ou seja:

$$m_1(\{R\}) + m_1(\{P\}) = 0.9 + 0.1 = 1$$

Assim, todas as hipóteses que não apresentam nenhuma evidência devem receber 0. Descrevendo matematicamente:

$$m_1(A) = 0, \text{ para } \forall A \in 2^\Theta, A \neq \{R\}, A \neq \{P\}$$

O segundo especialista supõe que o paciente possa estar gripado e atribui uma probabilidade básica de 0.8 a essa evidência, desse modo:

$$m_2(\{G\}) = 0.8$$

O mesmo especialista supõe que o paciente possa estar com pneumonia e atribui uma probabilidade de 0.2 para a evidência, assim:

$$m_2(\{P\}) = 0.2$$

Conforme o raciocínio apresentado pelo primeiro especialista, ele também atribuiu toda a sua crença em duas hipóteses diferentes, ou seja:

$$m_2(\{G\}) + m_2(\{P\}) = 0.8 + 0.2 = 1$$

Conseqüentemente, todas as hipóteses que não apresentem nenhuma evidência devem receber 0, assim:

$$m_2(A) = 0, \text{ para } \forall A \in 2^\Theta, A \neq \{G\}, A \neq \{P\}$$

A combinação das crenças é descrita na Tabela 3, levando em consideração que para o cálculo é necessário apenas efetuar a multiplicação do valor da crença do

primeiro médico com o valor atribuído pelo segundo médico, conforme apresentado pela fórmula 9 (Capítulo 3, Item 6):

$$m_n(Z) = \sum_{X \cap Y = Z} m_{n-2}(X) m_{n-1}(Y)$$

Tabela 3. Utilização da regra de Dempster para demonstrar o peso de conflito

| m_1 | m_2 | m_3 |
|--------------------|--------------------|---------------------|
| $m_1(\{R\}) = 0.9$ | $m_2(\{G\}) = 0.8$ | $m_3(\{\}) = 0.72$ |
| $m_1(\{P\}) = 0.1$ | $m_2(\{G\}) = 0.8$ | $m_3(\{\}) = 0.08$ |
| $m_1(\{R\}) = 0.9$ | $m_2(\{P\}) = 0.2$ | $m_3(\{\}) = 0.18$ |
| $m_1(\{P\}) = 0.1$ | $m_2(\{P\}) = 0.2$ | $m_3(\{P\}) = 0.02$ |

Assim aplicando a fórmula 12 para calcular o peso de conflito tem-se:

$$\kappa = \sum m(\phi)$$

$$\kappa = \sum (m_3(\{\})) = 0.72 + 0.08 + 0.18 = 0.98$$

Levando em consideração que para esse cálculo é necessário apenas efetuar a soma de todas as *bpa* das ocorrências de conjuntos vazios, como explicado anteriormente. Continuando o cálculo do peso de conflito aplica-se a fórmula 11:

$$\chi = 1 / 1 - \kappa$$

$$\chi = 1 / 1 - 0.98 = 50$$

Finalmente, com a utilização da fórmula 10, encontra-se o peso de conflito:

$$\text{con}(bel_1, bel_2) = \log(\chi)$$

$$\text{con}(bel_1, bel_2) = \log(50) \cong 1.699$$

Como existem intersecções que produzem o conjunto vazio, o novo denominador para a fórmula 8 (Capítulo 3, Item 4), é:

$$1 - \kappa = 0.02$$

Assim, com o valor do denominador alterado devem-se recalcular todas as *bpa* das ocorrências de conjuntos não vazios. Como pode-se observar na Tabela 3 a

única crença que precisa ser recalculada é $m_3(\{M\})$ e baseando-se na fórmula 8 seu novo valor passa a ser:

$$m_n(Z) = \frac{\sum_{X \cap Y = Z} m_{n-2}(X) m_{n-1}(Y)}{1 - \sum_{X \cap Y = \phi} m_{n-2}(X) m_{n-1}(Y)}$$

$$m_3(\{M\}) = 0.02 / 0.02 = 1$$

Pode-se notar que o resultado obtido é bem diferente daquele esperado pela intuição, ou seja, a probabilidade básica do paciente estar com pneumonia é mínima se observada individualmente ($m_1(\{P\}) = 0.1$ e $m_2(\{P\}) = 0.2$). Mas se for aplicada a regra de Dempster pode-se perceber que acontece o oposto.

Percebe-se que não é desejável a combinação de duas funções de crença quando κ for muito grande, verificando-se assim que não é possível efetuar as combinações corretamente quando o peso de conflito for maior que 0.6 (UCHÔA; PANOTIM; NICOLETTI, 1997).

3.8 RELAÇÃO ENTRE AS TEORIAS BAYESIANA E DE DEMPSTER-SHAFER

A TDS e a lógica bayesiana possuem mais diferenças que similaridades e essas características são amplamente discutidas pela comunidade científica ao longo dos anos. Como semelhança pode ser citada a medida de crença (*bel*), da TDS, que pode ser considerada uma medida de probabilidade (*Pr*), na teoria bayesiana, se todos os conjuntos das evidências forem *singletons*. Assim, $Pr(A) = Bel(A)$ se *A* for um conjunto com apenas um elemento (CAMPOS, 2005).

Na TDS a crença em uma determinada proposição *A* é igual a soma das crenças atribuídas pela função de *bpa* a cada um de seus subconjuntos, conforme apresentado na fórmula 4 (Capítulo 3, Item 3):

$$bel(A) = \sum_{B \subseteq A} m(B)$$

Assim, essa fórmula pode ser adaptada para a distribuição de probabilidade clássica. Desse modo:

$$P(A) = \sum_{x \in A} p(x)$$

Lembrando que A deve ser necessariamente um *singleton* para que essa característica das teorias possa ser considerada equivalente.

Carvalho (2001) descreve que diversos autores compararam as duas teorias concluindo que não existe uma capaz de modelar todos os tipos de incertezas e que ambas possuem suas vantagens e desvantagens, sendo muito difícil determinar qual a melhor dentre elas.

A lógica bayesiana, representada pelas redes bayesianas, permite diminuir a complexidade que um problema real pode trazer oferecendo um modelo computacional, focando a busca em grupos menores de evidências e eventos, e dividindo o raciocínio em pequenos conjuntos para facilitar a modelagem da incerteza (LUGER, 2004; RUSSEL; NORVIG, 2004).

Deve-se ressaltar que a utilização dessa técnica é interessante apenas quando se trata de incerteza por aleatoriedade, por esse motivo a literatura apresenta diversos tipos de formalismos.

A TDS modela a incerteza por ignorância e diferencia-se da lógica bayesiana, ao utilizar graus de crença, com intervalos de probabilidade, para representar o conhecimento. Assim, ao contrário de calcular a probabilidade de uma proposição, a TDS calcula a chance de uma evidência assumir uma determinada hipótese (RUSSEL; NORVIG, 2004).

As principais diferenças entre a TDS e a teoria da probabilidade estão resumidas na Tabela 4.

Tabela 4. Comparação entre a TDS e a lógica bayesiana

| TDS | Lógica bayesiana |
|---|--------------------|
| $m(\Theta)$ não precisa ser igual a 1 | $\sum_i P_i = 1$ |
| $m(X)$ e $m(X')$ não precisam ter nenhum relacionamento | $P(X) + P(X') = 1$ |
| $X \subseteq Y$, não indica que $m(X) \leq m(Y)$ | $P(X) \leq P(Y)$ |

Fonte: Adaptado de GIARRATANO, J.; RILEY, G. (1998)

A primeira comparação mostra que na TDS a crença atribuída ao conjunto de todas as hipóteses não necessariamente deve ser igual a um, diferente da teoria bayesiana na qual a soma da probabilidade de todas as hipóteses sempre deve resultar 1 (GIARRATANO; RILEY, 1998).

A segunda diferença apresentada mostra duas hipóteses, X e Y. Na TDS, se $X \subseteq Y$, o valor da crença atribuída por $m(X)$ não necessariamente deve ser menor que $m(Y)$. Segundo a lógica bayesiana, se $X \subseteq Y$, o valor de $P(X)$ sempre será maior que o de $P(Y)$ (GIARRATANO; RILEY, 1998).

A última comparação diz respeito à negação da hipótese. Pela teoria bayesiana a soma da probabilidade da hipótese com a probabilidade de sua negação sempre irá resultar 1. Na TDS isso nem sempre acontece (GIARRATANO; RILEY, 1998).

Percebe-se então que as duas teorias são bem distintas, possuindo suas próprias características, porém, pode-se citar uma última semelhança: ambas são muito eficientes na modelagem da incerteza.

Devido a essas e outras características ambas as teorias são muito utilizadas em aplicações e ferramentas diversas, como é o caso dos trabalhos correlatos apresentados nesta pesquisa.

4 TRABALHOS CORRELATOS

Os trabalhos apresentados nesse capítulo se referem a algumas aplicações e ferramentas encontradas que utilizam a TDS sendo descritos seus objetivos, metodologias, áreas de aplicação, resultados, entre outros.

Alguns dos objetivos abordados pelas aplicações são: a utilização de técnicas de fusão de sensores para melhorar a informação na área da robótica, classificação de imagens de satélites na área de geologia e cartografia e detecção de falhas em redes de sensores sem fio na área de telecomunicações.

A ferramenta descrita utiliza uma interface gráfica com o intuito de demonstrar a inferência da TDS de uma forma simples e prática. O *software* possui um material que apresenta as principais características da TDS com o qual o usuário é capaz de utilizar o sistema de uma maneira eficiente.

4.1 APLICAÇÕES

As aplicações descritas a seguir utilizam os conceitos da TDS para realização de alguma tarefa em específico, principalmente para as áreas de geologia, cartografia, sensoriamento remoto e computação gráfica. São quatro pesquisas nacionais, publicadas em congressos e periódicos, e uma dissertação de mestrado.

4.1.1 A Teoria da Incerteza Aplicada à Classificação de Imagens de Satélite

Este trabalho apresenta um teste metodológico desenvolvido no ano de 2003, em São Paulo, por pesquisadores da Universidade Estadual de Feira de Santana

(UEFS) em conjunto com o Departamento de Transportes – Laboratório de Geoprocessamento (EPUSP) de São Paulo (SANTOS; OHATA; QUINTANILHA, 2003).

O objetivo da pesquisa é comparar dois tipos de modelagem da incerteza aplicadas na classificação de imagens de satélites, a TDS e a lógica bayesiana, avaliando sua eficiência na definição de classes de uso do solo da região de Mogi das Cruzes (SP), sendo uma das teorias utilizadas a TDS (SANTOS; OHATA; QUINTANILHA, 2003).

As imagens utilizadas foram capturadas pelo satélite Landsat TM 7¹⁹ em 22 de abril de 2002. Os *softwares* utilizados para o processamento e análise de imagens foram o ENVI 3.0²⁰ e o IDRISI 32²¹. Por meio da utilização do algoritmo Isodata²² foi possível efetuar uma classificação para especificar as probabilidades *a priori* das classes (SANTOS; OHATA; QUINTANILHA, 2003).

Os algoritmos utilizados foram: a máxima verossimilhança²³, Bayclass²⁴, Belclass²⁵ e a TDS. A Figura 4 mostra a aplicação do algoritmo baseado na TDS para classificação da imagem levando em consideração quatro classes (água, vegetação, solo

¹⁹ Landsat 7 é um satélite da NASA que foi lançado da Base da Força Aérea de Vandenburg em 15 de abril de 1999. Sua função é fotografar os continentes da Terra para permitir aos pesquisadores estudar os vários aspectos do nosso planeta e para avaliar as mudanças causadas pelos processos naturais e as práticas humanas (NASA, 2008).

²⁰ O ENVI (Environment for Visualizing Images) é um tipo de programa utilizado em sensoriamento remoto, que trabalha com imagens adquiridas por sensores instalados em satélites ou aeronaves (MOREIRA et al, 2007).

²¹ IDRISI 3.2 é um programa de computador de geoprocessamento que utiliza algoritmos de transformação para processar as imagens do Landsat (COLTRI, 2006).

²² Isodata é uma técnica de classificação digital não supervisionada para a geração de mapas (GALVÃO; MENESES, 2005).

²³ A classificação por Máxima Verossimilhança é uma técnica de classificação supervisionada utilizada em dados de Sensoriamento Remoto (VIEIRA, 1996).

²⁴ Bayclass é um algoritmo de classificação de imagens que avalia a probabilidade de um determinado *pixel* pertencer a uma classe. Ele gera a matriz de incerteza da classificação e as matrizes de probabilidade para as classes (SANTOS; OHATA; QUINTANILHA, 2003).

²⁵ Belclass é um algoritmo que utiliza fundamentos da teoria bayesiana. Sua finalidade é determinar o grau de confiança em cada *pixel* e verificar a classe que ele pertence (SANTOS; OHATA; QUINTANILHA, 2003).

exposto e urbano) nas quais os *pixels* da imagem podem ser classificados (SANTOS; OHATA; QUINTANILHA, 2003).



Figura 4. Classificação da crença nas classes utilizando a TDS
Fonte: SANTOS, R.; OHATA, A.; QUINTANILHA, J. (2003)

Levando em consideração a utilização das quatro técnicas, os resultados obtidos foram amplamente aceitáveis, pois todas as teorias obtiveram resultados satisfatórios no processo de classificação das imagens (SANTOS; OHATA; QUINTANILHA, 2003).

4.1.2 Detecção de Falhas em Redes de Sensores sem Fio Baseada na Medição do Tráfego e em Técnicas de Fusão de Dados

Este trabalho foi desenvolvido em 2005 por pesquisadores ligados ao Departamento de Ciência da Computação da Universidade de Minas Gerais, em Belo Horizonte e também à Fundação Centro Análise, Pesquisa e Inovação Tecnológica, localizada em Manaus, Amazonas (NAKAMURA et al, 2005).

As tarefas fundamentais em redes de sensores sem fio²⁶, como a disseminação de dados, normalmente são feitas com o auxílio de esquemas de redes planas, com a utilização de topologias em árvore²⁷. As técnicas atuais não se preocupam com a reconstrução dessa topologia, sendo que o objetivo desse trabalho foi o de utilizar a TDS para identificar essa necessidade (NAKAMURA et al, 2005).

Os recursos utilizados para permitir a criação de uma solução viável, que detecta automaticamente quando a topologia de disseminação precisa ser reconstruída, foram: mecanismos de fusão de dados²⁸, o Filtro de Média Móvel²⁹ e a inferência de Dempster-Shafer. A Figura 5 ilustra o comportamento do sinal de tráfego de uma rede de sensores sem fio (NAKAMURA et al, 2005).




Figura 5. Comportamento do Sinal de Tráfego
Fonte: NAKAMURA, E. et al (2004)

A fusão de dados de sensores lida com a combinação de diversas fontes para melhorar a informação. É normalmente utilizada em tarefas de detecção e classificação para aplicações militares, robótica, detecção de intrusos, redução de tráfego de dados e economia de energia. A TDS foi utilizada para encontrar o estado do sistema

²⁶ Rede de Sensores sem Fio (RSSF) é um tipo de rede que possui um grande número de nós com capacidade de sensoriamento. São redes com diversas limitações que podem ser utilizadas em aplicações ambientais, médicas, industriais e militares. A principal finalidade de uma RSSF é coletar dados do ambiente enviar a um nó central para processamento (NAKAMURA et al, 2005).

²⁷ Topologias em árvore são usadas para disseminar dados em redes de sensores (NAKAMURA et al, 2005).

²⁸ Mecanismos de fusão de dados são utilizados para tratar o tráfego como um sinal que é filtrado e transformado em evidências, indicando a probabilidade de ocorrência de falhas (NAKAMURA et al, 2005).

²⁹ O Filtro de Média Móvel é utilizado para reduzir os ruídos no comportamento do tráfego de sinais nas redes de sensores sem fio (NAKAMURA et al, 2005).

(NORMAL ou CRITICO) por meio das evidências extraídas das características do tráfego (NAKAMURA et al, 2005).

Os resultados apontam que a fusão de dados é uma técnica que pode ser usada para otimizar o desempenho de algoritmos de disseminação de dados para redes de sensores sem fio evitando assim tráfego desnecessário (NAKAMURA et al, 2005).

4.1.3 Incerteza e Combinação de Evidências: A Questão dos Diamantes do Rio Tibagi-PR

Esta pesquisa referente à Dissertação de Mestrado de um dos autores foi desenvolvida em 1999, na cidade de Curitiba, por pesquisadores do Departamento de Geologia da Universidade Federal do Paraná e da pós-graduação da UNESP, com sede em Rio Claro, no estado de São Paulo (SOARES; PERDONCINI, 1999).

Em seu desenvolvimento foi utilizada a TDS para modelar a incerteza presente no raciocínio geológico, a partir de vinte e duas evidências levadas em consideração para avaliar duas hipóteses. A primeira diz respeito à fonte dos diamantes nos conglomerados basais³⁰ do Grupo Itararé e a segunda à fonte em rochas kimberlíticas-lamproíticas³¹ (SOARES; PERDONCINI, 1999).

Além de fatos geológicos referentes à área de estudo em discussão, a pesquisa aborda a TDS e todos os seus principais conceitos como a atribuição de probabilidade básica, a combinação das evidências e a plausibilidade. Além disso,

³⁰ Conglomerados basais são rochas com tamanho superior a dois milímetros, agrupadas por um cimento que formam um depósito consolidado (SUGUIO, 1980).

³¹ Rochas kimberlíticas-lamproíticas são uma variedade de rocha eruptiva e também a matriz do diamante (ENCICLOPAEDIA BRITANNICA, 1997).

avalia as proposições em um programa desenvolvido na linguagem BASIC³², gerando os resultados desejados (SOARES; PERDONCINI, 1999).

Com a metodologia utilizada foi concluído que, com uma grande quantidade de informações sobre uma determinada proposição, existe uma grande facilidade em chegar aos resultados desejados. A principal contribuição do trabalho está relacionada à possibilidade de considerar a ambigüidade geralmente presente na informação geológica utilizando a TDS (SOARES; PERDONCINI, 1999).

4.1.4 Investigação Sobre o uso de Dados Auxiliares no Processo de Classificação de Imagens Digitais Empregando Princípios da Teoria da Evidência

O presente trabalho desenvolvido no ano de 2007 por pesquisadores da Universidade Federal do Rio Grande do Sul, localizada na cidade de Porto Alegre em conjunto com o Instituto Nacional de Pesquisas Espaciais (INPE), com sede em São José dos Campos, São Paulo (LERSCH; HAERTEL; SHIMABUKURO, 2007).

O objetivo do estudo consiste na investigação do uso dos conceitos propostos pela TDS na classificação de imagens digitais em sensoriamento remoto³³. Nesse sentido, os dados auxiliares de diversas fontes são organizados de tal forma para criar as funções de crença (LERSCH; HAERTEL; SHIMABUKURO, 2007).

A metodologia proposta é descrita por meio de uma aplicação envolvendo uma área de teste real. Inicialmente é feita uma revisão dos princípios básicos da TDS e com isso é definida uma cena a ser classificada, estimando-se o grau de incerteza a cada

³² *Beginners All-purpose Symbolic Instruction Code* (BASIC) é uma linguagem de programação, criada em 1963 com fins didáticos e por esse motivo é muito simples e fácil de entender (DARTMOUTH COLLEGE COMPUTATION CENTER, 1964).

³³ Sensoriamento remoto é uma ferramenta importante para quantificar e qualificar os vários processos referentes ao uso e cobertura do solo e também para auxiliar a determinação da temperatura aparente das superfícies (COLTRI, 2006).

uma das classes presentes nessa cena. Para a implementação dessa metodologia foi desenvolvido um *software* em ambiente MATLAB³⁴ (LERSCH; HAERTEL; SHIMABUKURO, 2007).

Na região estudada são encontradas áreas cobertas por mata nativa com araucária. Por ser uma classe de cobertura do solo difícil de ser identificada com boa precisão, este experimento abordou uma metodologia com a finalidade de aumentar a precisão na identificação de manchas de mata nativa com araucária. Foram utilizados o sistema Landsat-TM 7 e o classificador Máxima Verossimilhança Gaussiana³⁵, para a classificação da cena (LERSCH; HAERTEL; SHIMABUKURO, 2007).

As principais contribuições do trabalho encontram-se na proposta de uma abordagem mais quantitativa quanto à utilização da informação fornecida pela função de crença e os resultados do estudo servem para descrever a aplicabilidade da metodologia proposta, provando a possibilidade de aumentar a precisão nas análises feitas com sensoriamento remoto (LERSCH; HAERTEL; SHIMABUKURO, 2007).

4.1.5 Mecanismo de Agregação de Dados Empregando Técnicas Paramétricas em Redes de Sensores

Essa dissertação de mestrado foi desenvolvida em 2004 por um pesquisador do Programa de Pós-Graduação de Engenharia Elétrica da Universidade Federal do Rio de Janeiro (PINTO, 2004).

³⁴ MATLAB é uma linguagem de alto nível que proporciona ao usuário um ambiente interativo, que permite a execução de tarefas computacionais, como cálculos complexos e criação de gráficos, com uma performance muito superior se comparado com linguagens de programação tradicionais, tais como C, C++ e Fortran (THE MATHWORKS, 2008).

³⁵ O método da Máxima Verossimilhança é um dos mais utilizados em sensoriamento remoto no que diz respeito à abordagem estatística. Ele utiliza alguns parâmetros estatísticos para distribuir valores em uma área de treinamento através de uma função de probabilidade baseada na lógica bayesiana (QUEIROZ; RODRIGUES; GÓMEZ, 2004).

Os sistemas de telecomunicações são a área de aplicação do estudo, tendo como objetivos: o estudo da Difusão Direcionada³⁶ e das técnicas de fusão de dados, propondo a adaptação de um mecanismo de agregação de dados utilizando a inferência bayesiana e a TDS em redes de sensores sem fio. O mecanismo baseado na TDS é apresentado no esquema descrito na Figura 6 (PINTO, 2004).

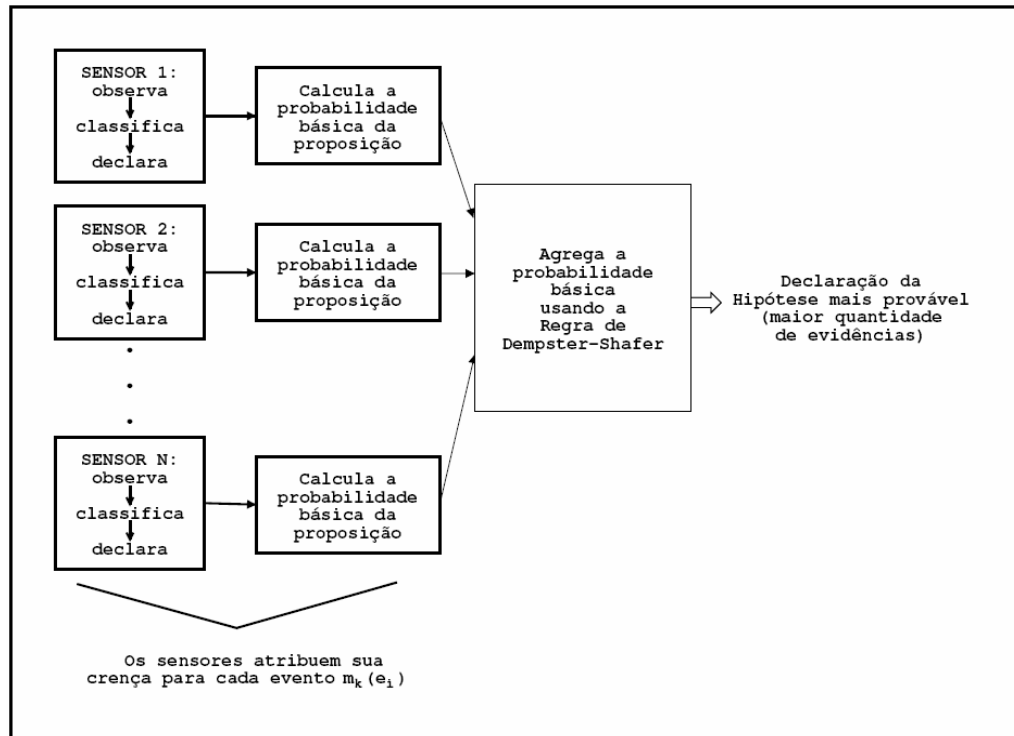


Figura 6. Processo de agregação baseado na inferência da TDS
Fonte: PINTO, A. (2004)

O mecanismo de agregação de dados tem por finalidade proporcionar a economia de energia reduzindo a comunicação entre os sensores da rede, juntamente com a transformação dos dados brutos em informações interessantes, minimizando dessa forma os impactos na robustez³⁷ e latência³⁸ da rede (PINTO, 2004).

O desempenho do mecanismo de agregação foi avaliado por meio do desenvolvimento de dois filtros, um para Bayes e outro para TDS, que foram

³⁶ Difusão Direcionada é um protocolo de redes de sensores sem fio no qual os nós trabalham de forma cooperativa com o intuito de processar e armazenar mensagens (PINTO, 2004).

³⁷ A robustez está relacionada à perda de pacotes durante a transmissão. Quanto mais robusta a rede menor é a perda (PINTO, 2004).

³⁸ A latência da rede diz respeito ao tempo decorrido entre o início e o fim de envio de uma mensagem sem levar em consideração o tempo de processamento gasto nos filtros da rede (PINTO, 2004).

adicionados ao módulo da Difusão Direcionada disponível no simulador *ns-2*³⁹ (PINTO, 2004).

As principais contribuições desse trabalho foram: a proposta de um mecanismo de agregação diferente do tradicional e os resultados das simulações que mostraram, para os testes realizados, uma economia de energia significativa com um baixo custo na rede (PINTO, 2004).

4.1.6 A Teoria de Dempster-Shafer como um Método de Inferência para Reconhecimento de Imagens Geométricas Distorcidas

Esse trabalho foi desenvolvido em 2003 por pesquisadores do INPE, da Universidade de Guarulhos, com sede na cidade de Guarulhos, São Paulo, e da Universidade Braz Cubas, que fica na cidade de Mogi das Cruzes, também no estado de São Paulo (SILVA; SIMIONI, 2003).

O objetivo da pesquisa é apresentar a aplicação dos métodos de raciocínio da TDS na incerteza presente nas imagens distorcidas provenientes da Visão Computacional⁴⁰. Um dos tópicos descreve as principais características da TDS, relacionando sua utilização com o estudo proposto (SILVA; SIMIONI, 2003).

A metodologia descreve a utilização da inferência da TDS, aplicando-a em pares de imagens que apresentam diferenças geométricas entre si, em uma tentativa de diminuir a dependência de pré-processamento. A idéia consiste em verificar os limites

³⁹ O *Network Simulator (ns-2)* é um simulador orientado a eventos amplamente utilizado em pesquisas de redes de comunicação. Ele utiliza as linguagens C++ e OTcl (*Object Tool Command Language*) garantindo um bom desempenho e flexibilidade ao simulador. O núcleo do simulador foi implementado em C++ e a interface utiliza scripts escritos em OTcl, o que permite a realização de modificações mais rapidamente (PINTO, 2004).

⁴⁰ Por meio da visão computacional é possível efetuar a investigação de questões computacionais e algorítmicas referentes à aquisição, processamento e compreensão de imagens (BIANCHI, 1998).

do modelo para estabelecer a correspondência de imagens em seu estado bruto, isto é, entre as imagens não processadas (SILVA; SIMIONI, 2003).

Os resultados apresentados mostram que quando as imagens comparadas possuem ângulos com valores muito diferentes, podem ocorrer grandes erros, se forem utilizados os mesmos parâmetros (como o tamanho da janela). No entanto, o sucesso alcançado por meio da aplicação da metodologia para imagens distorcidas mostra a importância de introduzir a modelagem da incerteza no processo (SILVA; SIMIONI, 2003).

4.2 FERRAMENTA

A ferramenta encontrada é descrita no item a seguir, sendo apresentados seus objetivos, área de aplicação, origem, entre outros.

4.2.1 Dempster-Shafer Engine

Dempster-Shafer Engine⁴¹ (DSE) é um *software* sem fins lucrativos que foi criado para uso educacional, desenvolvido em 1999 e encontra-se em sua versão 1.0 (O'NEILL, 1999).

O principal objetivo da ferramenta é demonstrar a utilização da inferência da TDS e sua utilidade prática. Pode ser utilizado para raciocinar sobre incertezas em diversos tipos de problemas de variadas áreas de atuação, levando em consideração as limitações pertinentes à teoria (O'NEILL, 1999).

⁴¹ Disponível em: <<http://aonaware.com/dse.htm>>.

Os recursos utilizados para sua implementação são baseados nos conceitos da TDS, como as funções de crença e plausibilidade, a *bpa*, a combinação de evidências, entre outros (O'NEILL, 1999).

O programa foi implementado para o sistema operacional Windows e possui uma interface com menus e barras de status conforme ilustra a Figura 7. Na parte superior encontra-se o menu de opções, que permite cadastrar novas hipóteses e evidências e ainda efetuar a combinação delas com a utilização da regra de Dempster (O'NEILL, 1999).

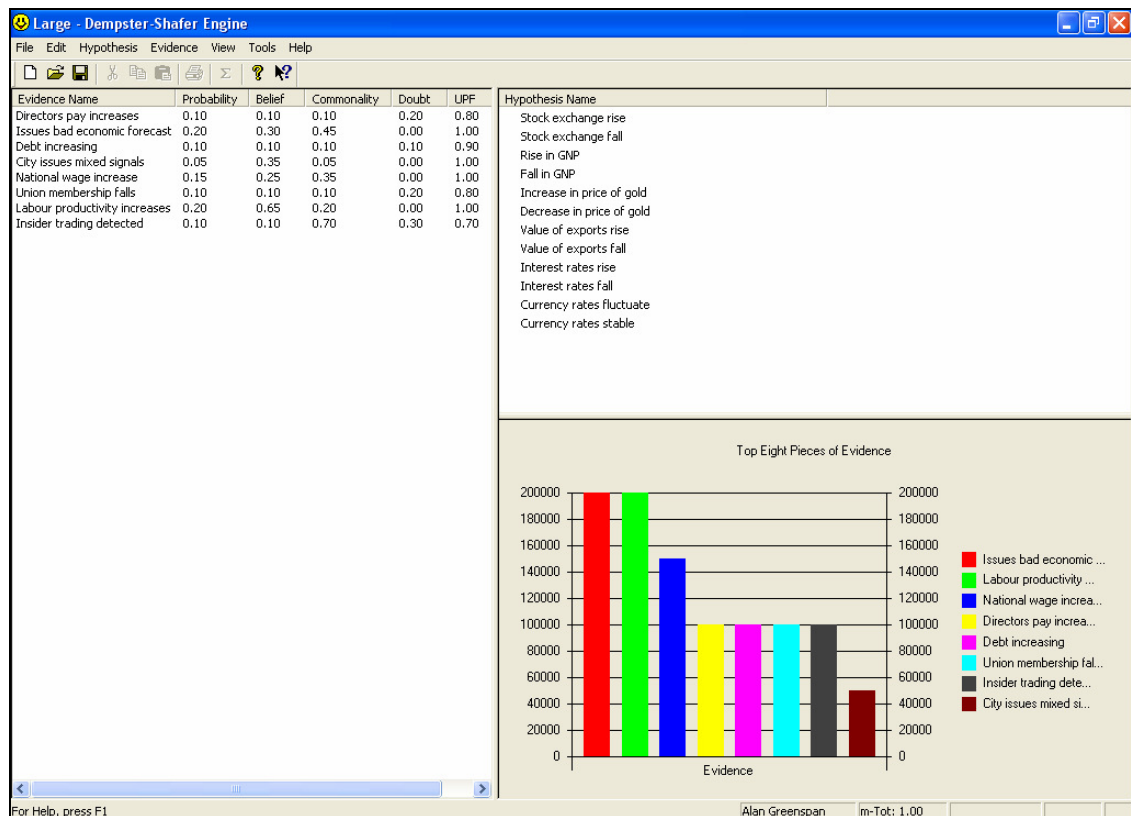


Figura 7. Interface do Dempster-Shafer *Engine*
Fonte: O'NEILL, A. (1999)

O programa é funcional e efetua os cálculos com precisão. Possui um módulo de ajuda e um tutorial que ensina qualquer usuário a utilizar o programa de maneira correta. É uma excelente ferramenta, gratuita e fácil de usar.

Como se pode perceber a TDS é aplicada em diversas áreas, sendo muito eficaz na modelagem da incerteza por ignorância. Os trabalhos apresentados

comprovam essa afirmação e evidenciam como podem ser úteis as aplicações e ferramentas baseadas em técnicas da TDS.

5 O FORMALISMO DA TEORIA DE DEMPSTER-SHAFER NA *SHELL* PARA MODELAGEM DA INCERTEZA PEGASUS

O Grupo de Pesquisa em Inteligência Computacional Aplicada⁴² da UNESC está desenvolvendo uma *shell* de modelagem da incerteza denominada Pegasus *Uncertainty Modeling* que abrange inicialmente quatro módulos. Cada um deles utiliza um formalismo matemático diferente para essa modelagem (redes bayesianas, lógica *fuzzy*, fatores de certeza e teoria de Dempster-Shafer), sendo que o presente trabalho tem por objetivo apresentar o formalismo da TDS.

Durante o desenvolvimento do trabalho foi realizado o levantamento bibliográfico, a modelagem matemática da TDS, a modelagem do motor de inferência baseado na TDS para a *shell* de modelagem de incerteza Pegasus, a implementação do módulo da TDS, a integração desse módulo na *shell* Pegasus, finalizando com os testes e resultados obtidos.

5.1 LEVANTAMENTO BIBLIOGRÁFICO

Nessa etapa foi realizado o estudo da TDS e dos formalismos existentes para a modelagem da incerteza por meio desta teoria.

Os materiais utilizados para esse estudo foram principalmente livros nacionais e internacionais, artigos científicos publicados em anais de congressos ou periódicos científicos, teses de doutorado, dissertações de mestrado, trabalhos de conclusão de curso e demais pesquisas científicas.

⁴² <<http://www.unesc.net/ica>>.

5.2 MODELAGEM MATEMÁTICA

No desenvolvimento dessa etapa do projeto foi adaptada uma BC da área da saúde que contém doenças relacionadas a lombalgia, desenvolvida em 2001, conforme o anexo B (SCUSSEL, 2001).

Scussel (2001) descreve que lombalgia é a dor ou indicação clínica causada por alguma patologia na região lombar do paciente, existindo cerca de 50 doenças que causam essa dor, sendo que a BC apresenta apenas seis, devido a alta prevalência (SCUSSEL, 2001).

A BC foi escolhida por apresentar um assunto abordado em outras pesquisas realizadas na UNESC (SCUSSEL, 2001; GOULARTE, 2002; GOULART, 2007; VALDATI, 2008) que envolvem modelagem da incerteza e por opinião do especialista que considerou ser relevante a aplicação da TDS.

Esse assunto foi tratado inicialmente por meio do formalismo das redes bayesianas apresentando as seguintes hipóteses diagnósticas: artrite, espondilite anquilosante, artrite reumatóide, espondilolistese e lombalgia muscular.

O processo de construção da rede bayesiana foi apresentado no trabalho desenvolvido em 2001, no curso de Ciência da Computação da UNESC. Na construção da BC foram coletados dados pelo especialista em Ortopedia e Traumatologia e professor do curso de medicina da UNESC, Robson Luiz dos Santos (SCUSSEL, 2001).

As hipóteses diagnósticas são ilustradas na Figura 8 por meio da interface gráfica da *shell* Netica.

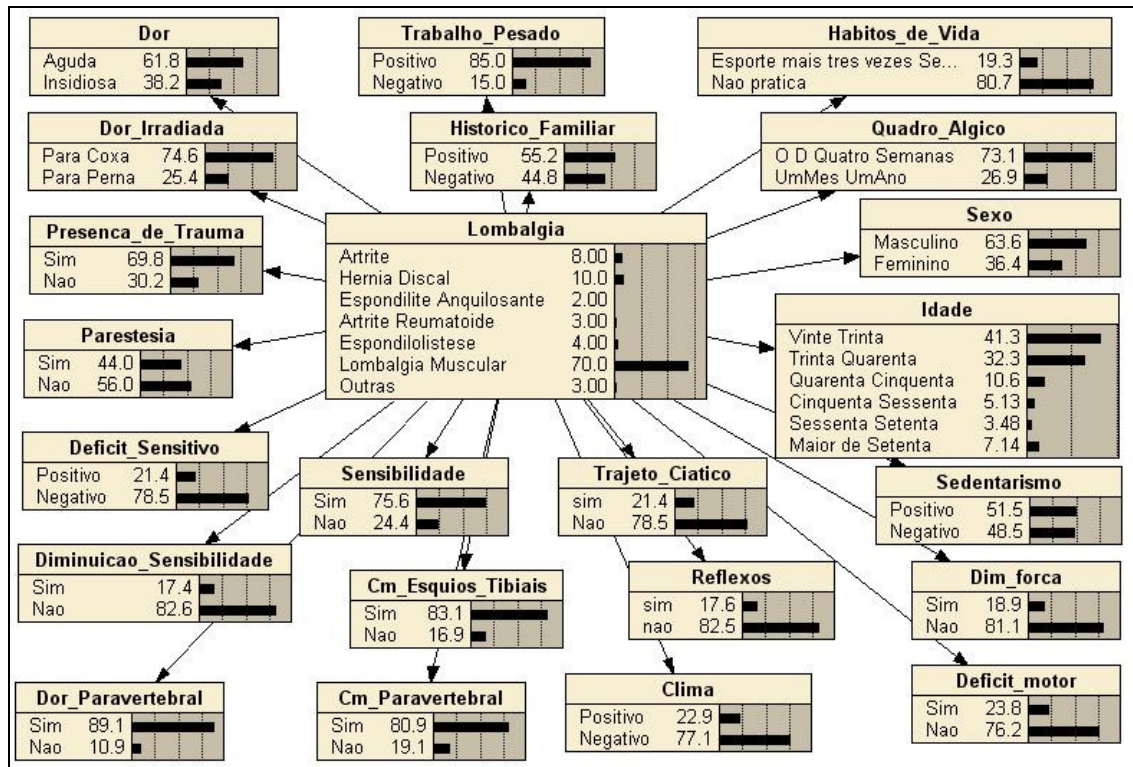


Figura 8. Base de Conhecimento da lombalgia
Fonte: SCUSSEL, T. (2001)

A fim de facilitar a simulação de diagnósticos por diferentes especialistas em casos hipotéticos, optou-se em utilizar esta rede bayesiana desenvolvida por Scussel (2001) para representar as hipóteses utilizadas no estudo de caso. Assim, os valores *a posteriori* das evidências e hipóteses diagnósticas da base de conhecimento de lombalgia foram utilizados para o cálculo da TDS.

As hipóteses utilizadas foram elaboradas a partir das seleções feitas na rede bayesiana resultando o domínio do problema em $\Theta = (\text{Artrite } \{A\}, \text{Hérnia Discal } \{HD\}, \text{Espondilite Anquilosante } \{EA\}, \text{Artrite Reumatoide } \{AR\}, \text{Espondilolistese } \{E\}, \text{Lombalgia Muscular } \{LM\}, \text{Outras } \{O\})$.

Assim, para determinar as evidências conforme explicado anteriormente, o especialista deve verificar os sinais e sintomas do paciente e efetuar a seleção na rede bayesiana ilustrada na Figura 8 verificando quais as prováveis doenças. Essas probabilidades representam então os valores que são utilizados para modelagem matemática e para entrada na lista das evidências.

Desse modo, para a modelagem matemática é descrito um caso fictício com um senhor chamado Luiz da Silva. Ele é um pedreiro que trabalha de segunda a sábado, das 7h às 18h, tem 55 anos e não pensa em se aposentar tão cedo. Nas últimas semanas ele vem sentindo uma diminuição em sua força física e algumas dores na região lombar.

Ao chegar no consultório ele é atendido e o médico (1º especialista) começa a lhe fazer algumas perguntas registrando as respostas na rede bayesiana apresentada na Figura 8. Os sinais e sintomas observados pelo especialista foram: trabalho pesado, não pratica esportes, ausência de trauma, histórico familiar positivo, sexo masculino, idade entre 50 e 60 anos, não é sedentário (devido a sua profissão), não possui diminuição de força, não possui diminuição de sensibilidade e não possui déficit motor. Finalizada a anamnese⁴³, a BC se encontra como na Figura 9.

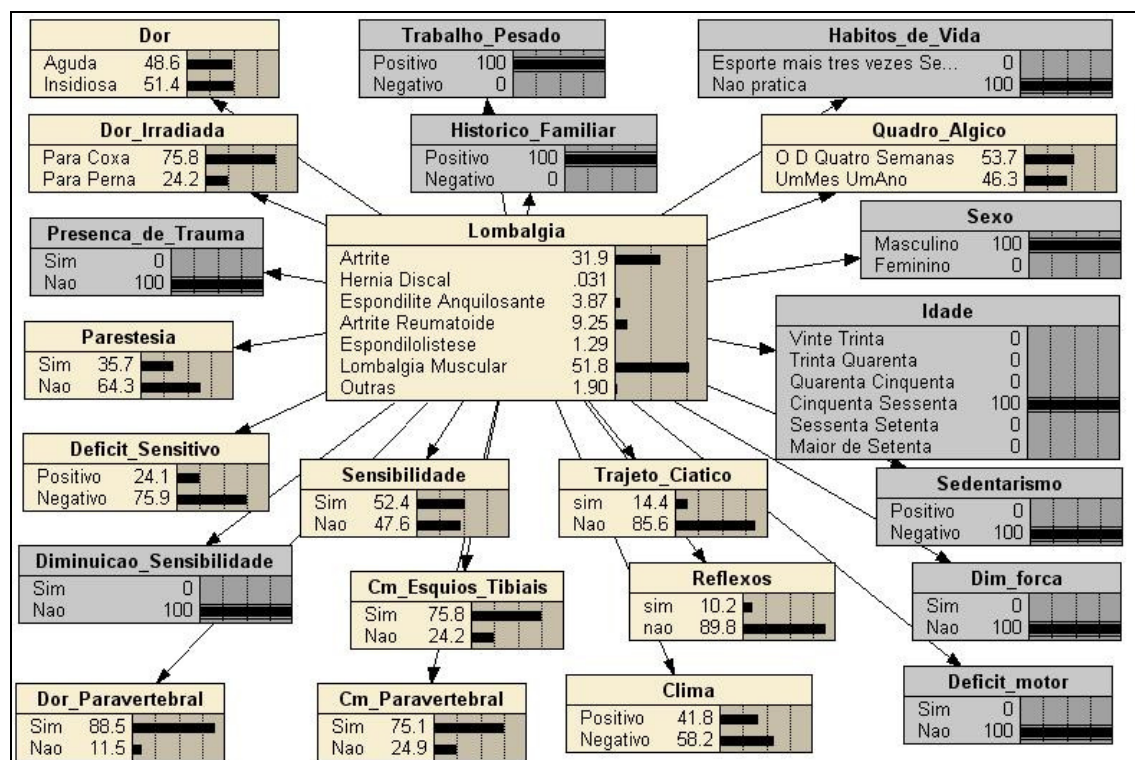


Figura 9. Base de Conhecimento da lombalgia preenchida pelo especialista 1

⁴³ Método para a avaliação de um diagnóstico médico (TALLEY; O'CONNOR, 2000).

O 1º especialista relata então ao paciente que ele tem 51,8% de chance de estar com lombalgia muscular (hipótese diagnóstica com maior probabilidade associada) e explica sobre a doença propondo um tratamento.

Ao sair do consultório o paciente possui então a seguinte informação, que indica a crença ($m_1(\{LM\})$) do 1º especialista baseada na probabilidade da existência de lombalgia muscular verificada durante a análise das hipóteses diagnósticas da rede bayesiana.

$$m_1(\{LM\}) = 0.518$$

Assim, como descrito por Sentz e Ferson (2002), a soma de todas as atribuições feitas aos subconjuntos de Θ deve ser igual a 1, conforme indica a fórmula 3 (Capítulo 3, Item 2):

$$\sum_{A \in 2^\Theta} m(A) = 1$$

Dessa maneira, como o paciente não questionou sobre as probabilidades das demais hipóteses diagnósticas, o valor 0.482 deve ser atribuído a $m_1(\Theta)$, indicando a crença nas demais hipóteses diagnósticas na rede bayesiana.

$$m_1(\Theta) = 0.482$$

Dessa maneira, todas as outras *bpa* devem receber 0, ou seja, todas as *bpa* dos conjuntos de hipóteses diferentes de Lombalgia Muscular $\{LM\}$ e Θ devem receber 0. Descrevendo matematicamente tem-se:

$$m_1(A) = 0, \text{ para } \forall A \in 2^\Theta, A \neq \{LM\}, A \neq \Theta$$

O paciente resolve então procurar outro especialista a fim de reforçar o diagnóstico e tratamento do 1º. O 2º especialista utiliza o mesmo método de perguntas do 1º e usa a mesma rede bayesiana, e ao finalizar a consulta, verifica os seguintes sinais e sintomas: trabalho pesado, não pratica esportes, ausência de trauma, histórico familiar positivo, sexo masculino, idade entre 50 e 60 anos, não é sedentário, não possui

diminuição de força, não possui diminuição de sensibilidade, não possui déficit motor e possui déficit sensitivo. Assim, a hipótese diagnóstica mais significativa é a artrite, com uma probabilidade de 59,4%, conforme ilustra a Figura 10.

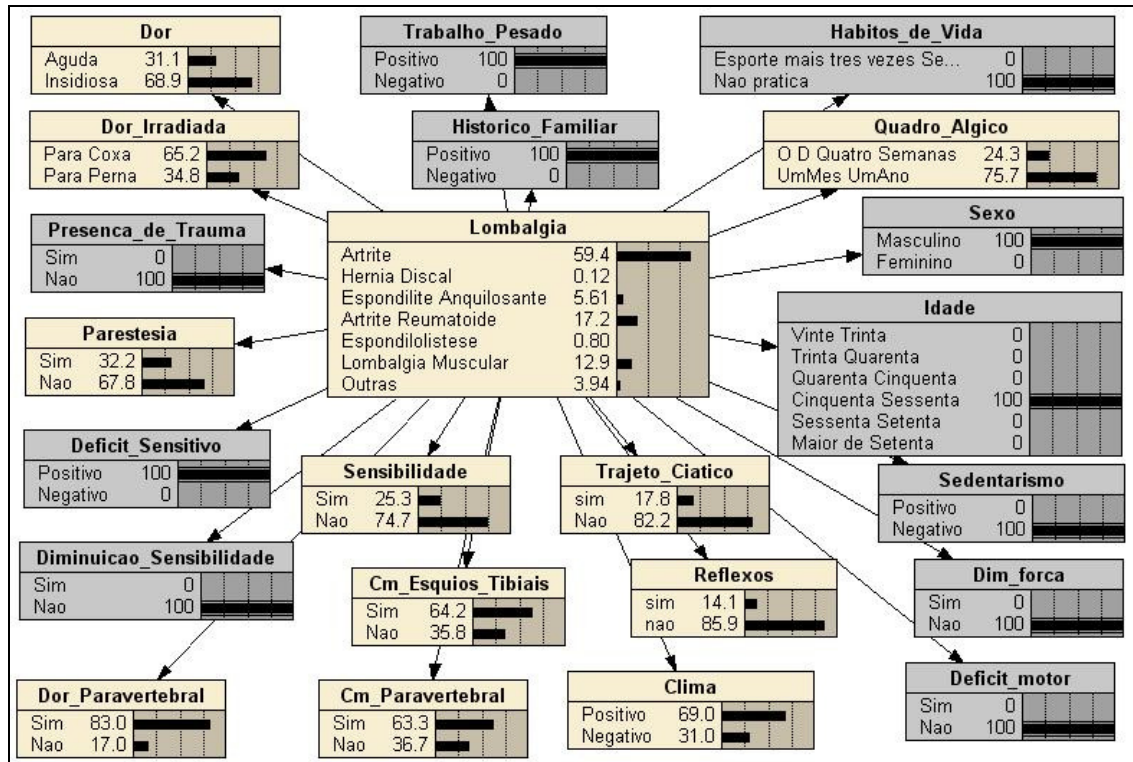


Figura 10. Base de Conhecimento da lombalgia preenchida pelo especialista 2

Pode-se verificar que o 2º especialista observou uma evidência que o 1º não tinha percebido (Deficit_Sensitivo), resultando no diagnóstico apresentado ser diferente do anterior.

Com isso o 2º especialista descreve que o paciente tem 59,4% de chance de estar com artrite e lhe propõe um tratamento.

Finalizada a segunda consulta, o paciente compara as duas recomendações de tratamento e diagnóstico realizado e observa que apresenta dois diagnósticos e tratamentos distintos.

Assim são apresentadas outras informações para utilização na modelagem matemática pela TDS, que indica a crença ($m_2(\{A\})$) do 2º especialista baseada na análise das hipóteses diagnósticas da rede bayesiana.

$$m_2(\{A\}) = 0.594$$

E como o paciente também não questionou sobre as probabilidades das demais hipóteses diagnósticas, o valor 0.406 deve ser atribuído a $m_2(\Theta)$, indicando a crença nas demais hipóteses diagnósticas na rede bayesiana. Dessa forma:

$$m_2(\Theta) = 0.406$$

Assim, todas as outras *bpa* devem receber 0, ou seja, todas as *bpa* dos conjuntos de hipóteses diferentes de Artrite $\{A\}$ e Θ devem receber 0. Descrevendo matematicamente tem-se:

$$m_2(A) = 0, \text{ para } \forall A \in 2^\Theta, A \neq \{A\}, A \neq \Theta$$

Nesse momento pode-se utilizar a fórmula 8 (Capítulo 3, Item 4) para combinar as evidências dos dois especialistas.

$$m_n(Z) = \frac{\sum_{X \cap Y = Z} m_{n-2}(X) m_{n-1}(Y)}{1 - \sum_{X \cap Y = \emptyset} m_{n-2}(X) m_{n-1}(Y)}$$

A Tabela 5 apresenta o início do cálculo mostrando apenas a intersecção das hipóteses e a multiplicação dos valores do numerador. A primeira coluna apresenta os valores das crenças nas hipóteses verificadas pelo 1º especialista (m_1), a segunda coluna apresenta os valores das crenças nas hipóteses verificadas pelo 2º especialista (m_2) e a 3ª coluna apresenta os valores das crenças combinadas entre m_1 e m_2 , ou seja, a multiplicação dos valores e a intersecção dos conjuntos de m_1 e m_2 .

O valor de m_3 é considerado inicialmente provisório, pois depende da verificação das evidências que possuem conjuntos de hipóteses nulos.

Tabela 5. Combinação das evidências no caso da lombalgia para obtenção de m_3

| m_1 | m_2 | m_3 (provisório) |
|-----------------------|-----------------------|---------------------------|
| $m_1(\{LM\}) = 0.518$ | $m_2(\{A\}) = 0.594$ | $m_3(\{\}) \cong 0.308$ |
| $m_1(\Theta) = 0.482$ | $m_2(\{A\}) = 0.594$ | $m_3(\{A\}) \cong 0.286$ |
| $m_1(\{LM\}) = 0.518$ | $m_2(\Theta) = 0.406$ | $m_3(\{LM\}) \cong 0.21$ |
| $m_1(\Theta) = 0.482$ | $m_2(\Theta) = 0.406$ | $m_3(\Theta) \cong 0.196$ |

Pode-se perceber que a soma das crenças atribuídas pela função de *bpa* é igual a 1, provando assim a fórmula 3 (Capítulo 3, Item 2), ou seja:

$$\sum_{A \in 2^{\Theta}} m(A) = 1$$

$$m_3(\{\}) + m_3(\{A\}) + m_3(\{LM\}) + m_3(\Theta) = 0.308 + 0.286 + 0.21 + 0.196 = 1$$

Continuando o raciocínio, como existe um conjunto de hipóteses vazio ($m_3(\{\})$) a crença deve ser normalizada. Assim o denominador a ser utilizado na aplicação da fórmula 8 (Capítulo 3, Item 4) é:

$$m_n(Z) = \frac{\sum_{X \cap Y = Z} m_{n-2}(X) m_{n-1}(Y)}{1 - \sum_{X \cap Y = \emptyset} m_{n-2}(X) m_{n-1}(Y)}$$

$$1 - m_3(\{\}) \cong 1 - 0.308 \cong 0.692$$

O resultado da crença combinada (m_3) dos dois especialistas é então:

$$m_3(\{A\}) \cong 0.286 / 0.692 \cong 0.414$$

$$m_3(\{LM\}) \cong 0.21 / 0.692 \cong 0.304$$

$$m_3(\Theta) \cong 0.196 / 0.692 \cong 0.283$$

Pode-se perceber uma pequena diferença entre as crenças $m_3(\{A\})$ e $m_3(\{LM\})$ e pela proximidade dos valores o especialista pode ficar em dúvida no processo de tomada de decisão.

Por não saber qual o tratamento médico seguir em virtude da disparidade entre os diagnósticos, o paciente resolve fazer uma terceira consulta. Assim, o 3º especialista utiliza a mesma forma de diagnose dos outros dois especialistas e verifica as mesmas evidências que o 2º especialista observou (Figura 10). Então relata que o paciente possui 59,4% de chance de ter artrite.

O paciente então expõe os outros diagnósticos ao 3º especialista e questiona o porquê do 1º especialista afirmar que ele tinha grandes chances de estar com lombalgia muscular.

Assim, o 3º especialista lhe explica que verificou as evidências e baseou-se nelas para estabelecer as probabilidades, e também afirma conforme os resultados apresentados pela consulta à rede bayesiana que o paciente possui mais chance de ter artrite reumatóide ($m_4(\{AR\}) = 0.172$), que foi a segunda hipótese diagnóstica com maior probabilidade associada, do que lombalgia muscular ($m_4(\{LM\}) = 0.129$), a terceira maior probabilidade.

Como verificado o 3º especialista não observou os diagnósticos dos especialistas anteriores. Porém, se fossem levadas em consideração as consultas anteriores, a aplicação da fórmula 8 (Capítulo 3, Item 4) para combinação das evidências poderia ser utilizada.

Nesse caso, além de m_3 (representando a crença combinada dos dois primeiros especialistas), seriam utilizadas as probabilidades de maior valor confirmadas pelo 3º especialista. Assim, conforme os dados apresentados pelo 3º especialista, as novas informações seriam respectivamente para artrite, artrite reumatóide e lombalgia muscular:

$$m_4(\{A\}) = 0.594$$

$$m_4(\{AR\}) = 0.172$$

$$m_4(\{LM\}) = 0.129$$

Supondo ainda que o 3º especialista não tenha informado nenhuma outra hipótese diagnóstica ao paciente então deve-se atribuir o valor 0.105 à $m_4(\Theta)$ confirmando assim a fórmula 3 (Capítulo 3, Item 2), desse modo:

$$\sum_{A \in 2^{\Theta}} m(A) = 1$$

$$m_4(\Theta) + m_4(\{A\}) + m_4(\{AR\}) + m_4(\{LM\}) = 0.105 + 0.594 + 0.172 + 0.129 = 1$$

Assim, todas as outras *bpa* devem receber 0, ou seja, as *bpa* dos conjuntos de hipóteses diferentes de artrite {A}, artrite reumatóide {AR}, lombalgia muscular {LM} e Θ devem receber 0. Descrevendo matematicamente tem-se:

$$m_4(A) = 0, \text{ para } \forall A \in 2^{\Theta}, A \neq \{A\}, A \neq \{AR\}, A \neq \{LM\}, A \neq \Theta$$

A Tabela 6 apresenta o cálculo mostrando apenas a intersecção das hipóteses e a multiplicação dos valores do numerador referente a fórmula 8 (Capítulo 3, Item 4). A primeira coluna apresenta os valores da crença combinada dos dois primeiros especialistas (m_3), a segunda coluna apresenta os valores das crenças nas hipóteses verificadas pelo 3º especialista (m_4) e a 3ª coluna apresenta os valores das crenças combinadas entre m_3 e m_4 .

O valor de m_5 é considerado inicialmente provisório, pois depende da verificação das evidências que possuem conjuntos de hipóteses nulos.

Tabela 6. Combinação das evidências no caso da lombalgia para obtenção de m_4

| m_3 | m_4 | m_5 (provisório) |
|---------------------------|-----------------------|---------------------------|
| $m_3(\{A\}) \cong 0.414$ | $m_4(\{A\}) = 0.594$ | $m_5(\{A\}) \cong 0.246$ |
| $m_3(\{LM\}) \cong 0.304$ | $m_4(\{A\}) = 0.594$ | $m_5(\{\}) \cong 0.181$ |
| $m_3(\Theta) \cong 0.283$ | $m_4(\{A\}) = 0.594$ | $m_5(\{A\}) \cong 0.168$ |
| $m_3(\{A\}) \cong 0.414$ | $m_4(\{AR\}) = 0.172$ | $m_5(\{\}) \cong 0.071$ |
| $m_3(\{LM\}) \cong 0.304$ | $m_4(\{AR\}) = 0.172$ | $m_5(\{\}) \cong 0.052$ |
| $m_3(\Theta) \cong 0.283$ | $m_4(\{AR\}) = 0.172$ | $m_5(\{AR\}) \cong 0.049$ |
| $m_3(\{A\}) \cong 0.414$ | $m_4(\{LM\}) = 0.129$ | $m_5(\{\}) \cong 0.053$ |
| $m_3(\{LM\}) \cong 0.304$ | $m_4(\{LM\}) = 0.129$ | $m_5(\{LM\}) \cong 0.039$ |
| $m_3(\Theta) \cong 0.283$ | $m_4(\{LM\}) = 0.129$ | $m_5(\{LM\}) \cong 0.036$ |
| $m_3(\{A\}) \cong 0.414$ | $m_4(\Theta) = 0.105$ | $m_5(\{A\}) \cong 0.043$ |
| $m_3(\{LM\}) \cong 0.304$ | $m_4(\Theta) = 0.105$ | $m_5(\{LM\}) \cong 0.032$ |
| $m_3(\Theta) \cong 0.283$ | $m_4(\Theta) = 0.105$ | $m_5(\Theta) \cong 0.03$ |

Como existem conjuntos de hipóteses iguais devem-se somar suas *bpa*, conforme o numerador da fórmula 8 (Capítulo 3, Item 4).

$$m_n(Z) = \frac{\sum_{X \cap Y = Z} m_{n-2}(X) m_{n-1}(Y)}{1 - \sum_{X \cap Y = \emptyset} m_{n-2}(X) m_{n-1}(Y)}$$

Assim:

$$m_5(\{A\}) \cong 0.246 + 0.168 + 0.043 \cong 0.457$$

$$m_5(\{LM\}) \cong 0.039 + 0.036 + 0.032 \cong 0.107$$

Além disso, deve-se levar em consideração a existência de intersecções que produzem o conjunto vazio. Por esse motivo, o denominador para a fórmula 8 (Capítulo 3, Item 4) não é mais igual a 1, mas sim:

$$1 - \Sigma(m_5\{\}) \cong 1 - (0.181 + 0.071 + 0.052 + 0.053) \cong 0.642$$

Dessa forma m_5 deve ser recalculado devido a existência das evidências que possuem o conjunto de hipóteses vazio. Para encontrar a função da crença combinada m_5 , deve-se dividir o valor da crença provisória apresentada na Tabela 6 pelo novo denominador. A partir da utilização da fórmula 8 (Capítulo 3, Item 4), tem-se as crenças combinadas em artrite {A}, artrite reumatóide {AR}, lombalgia muscular {LM} e Θ :

$$m_5(\{A\}) \cong 0.457 / 0.642 \cong 0.711$$

$$m_5(\{AR\}) \cong 0.049 / 0.642 \cong 0.076$$

$$m_5(\{LM\}) \cong 0.107 / 0.642 \cong 0.167$$

$$m_5(\Theta) \cong 0.03 / 0.642 \cong 0.046$$

Os valores de $m_5(\text{conjunto})$ representam a crença em cada conjunto, e com eles é possível calcular a crença total e a plausibilidade, intervalo que representa o quanto se pode acreditar nas probabilidades calculadas. Com a utilização das fórmulas 4 e 7 (Capítulo 3, Item 3) será mostrado como ficam os intervalos.

$$bel(A) = \sum_{B \subseteq A} m(B) \qquad pl(A) = \sum_{B \cap A = \emptyset} m(B)$$

A crença na hipótese do paciente apresentar artrite ($bel(\{A\})$) é calculada por meio da soma de todas as bpa dos conjuntos de hipóteses contidos ou iguais a {A} e para calcular a plausibilidade na hipótese do paciente apresentar artrite ($pl(\{A\})$) deve-se somar todas as bpa dos conjuntos de hipóteses cuja intersecção com {A} não resulte em um conjunto vazio. Assim, o intervalo [$bel(\{A\}), pl(\{A\})$] resulta em:

$$[bel(\{A\}), pl(\{A\})] = [m(\{A\}), m(\{A\}) + m(\Theta)] = [0.711, 0.711 + 0.046]$$

$$[bel(\{A\}), pl(\{A\})] = [0.711, 0.757]$$

Os demais intervalos são calculados da mesma forma. Para:

a) artrite reumatóide {AR}:

$$[bel(\{AR\}), pl(\{AR\})] = [m(\{AR\}), m(\{AR\}) + m(\Theta)] = [0.076, 0.076 + 0.046]$$

$$[bel(\{AR\}), pl(\{AR\})] = [0.076, 0.122]$$

b) lombalgia muscular {LM}:

$$[bel(\{LM\}), pl(\{LM\})] = [m(\{LM\}), m(\{LM\}) + m(\Theta)] = [0.167, 0.167 + 0.046]$$

$$[bel(\{LM\}), pl(\{LM\})] = [0.167, 0.213]$$

c) domínio do problema (Θ):

$$[bel(\Theta), pl(\Theta)] = [m(\Theta) + m(\{A\}) + m(\{AR\}) + m(\{LM\}),$$

$$m(\Theta) + m(\{A\}) + m(\{AR\}) + m(\{LM\})]$$

$$[bel(\Theta), pl(\Theta)] = [0.046 + 0.711 + 0.076 + 0.167, 0.046 + 0.711 + 0.076 + 0.167]$$

$$[bel(\Theta), pl(\Theta)] = [1, 1]$$

A partir desse cálculo pode-se observar que a crença total apresenta a soma de todas as outras *bpa*, o que não ocorre conseqüentemente nos demais intervalos que representam parte do domínio do problema.

Assim, estes resultados representam o limite mínimo e máximo em que o especialista pode confiar para tomar sua decisão, para:

a) artrite: $[bel(\{A\}), pl(\{A\})] = [0.711, 0.757]$;

b) artrite reumatoide: $[bel(\{AR\}), pl(\{AR\})] = [0.076, 0.122]$;

c) lombalgia muscular: $[bel(\{LM\}), pl(\{LM\})] = [0.167, 0.213]$;

d) domínio do problema: $[bel(\Theta), pl(\Theta)] = [1, 1]$

Finalizada a definição dos intervalos de crença e plausibilidade, segue-se com o cálculo do peso de conflito para verificar a viabilidade da utilização da regra de Dempster. Assim, aplicando a fórmula 12 (Capítulo 3, Item 7), onde:

$$\kappa = \sum m(\phi)$$

Deve-se efetuar a soma de todos as crenças $m_5\{\}$ da terceira coluna da Tabela 6 para determinar o valor de κ :

$$\kappa = \Sigma(m_5\{\}) = 0.181 + 0.071 + 0.052 + 0.053 = 0.358$$

Desse modo deve-se então utilizar a fórmula 11 (Capítulo 3, Item 7), onde $\chi = 1 / (1 - \kappa)$, assim:

$$\chi = 1 / (1 - 0.358) \cong 1.557$$

Para concluir o cálculo do peso de conflito deve-se então aplicar a fórmula 10 (Capítulo 3, Item 7), onde $con(bel_1, bel_2) = \log(\chi)$, dessa forma o conflito entre m_3 e m_4 :

$$con(m_3, m_4) = \log(1.557) \cong 0.192$$

Pode-se notar que o resultado obtido está dentro dos limites estabelecidos da teoria, que indica valores menores ou iguais a 0.6 (UCHÔA; PANOTIM; NICOLETTI, 1997).

Assim pode-se inferir que, se no exemplo anterior, o 3º especialista tivesse modelado seu conhecimento por meio da TDS e visualizado o intervalo de crença e plausibilidade que tende a 1, onde $[bel(\{A\}), pl(\{A\})] = [0.711, 0.757]$, talvez esta informação pudesse confirmar sua decisão, inicialmente representada por meio da rede bayesiana com a probabilidade de 59,4% para artrite.

Com a modelagem matemática concluída é possível verificar os passos para o desenvolvimento do motor de inferência.

5.3 MODELAGEM DO MOTOR DE INFERÊNCIA

O processo de modelagem do motor de inferência foi efetuado de acordo com o levantamento bibliográfico realizado, e como o MI é um interpretador da base de

conhecimento, ele aplica determinados procedimentos para a solução de problemas, no caso, formalismos matemáticos fundamentados na TDS.

Assim os formalismos da TDS são representados na inferência pelo esquema apresentado na Figura 11 que ilustra a modelagem do motor de inferência pela TDS na *shell* Pegasus.

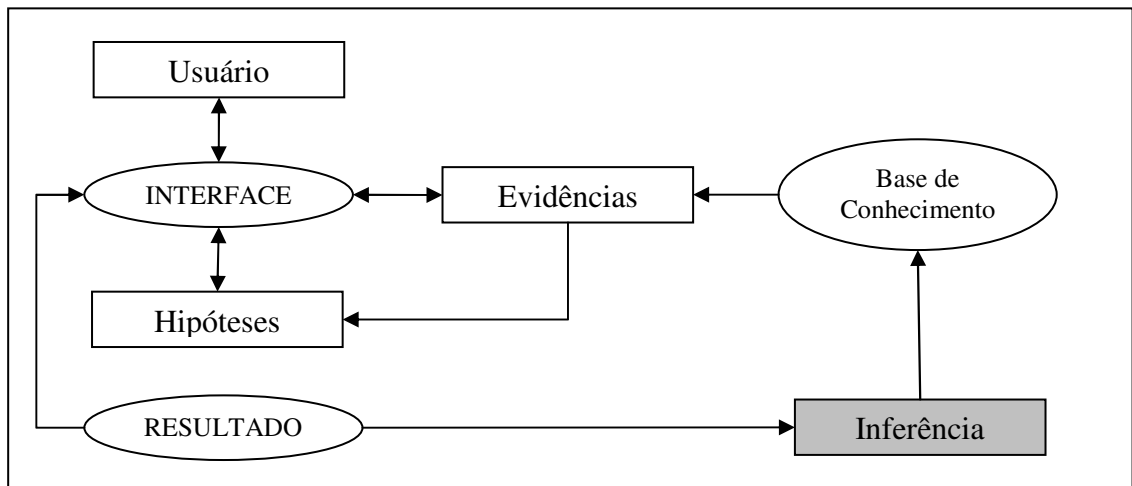


Figura 11. Modelagem do módulo baseado na TDS

A partir deste diagrama é possível observar como funciona o módulo da TDS na *shell* Pegasus desde seu início até a apresentação dos resultados. A interface auxilia o usuário a efetuar a desenvolver a Base de Conhecimento além de realizar consultas. Quando a BC está completa os resultados são processados pelo motor de inferência e apresentados ao usuário.

A Figura 12 descreve como a Inferência foi modelada.

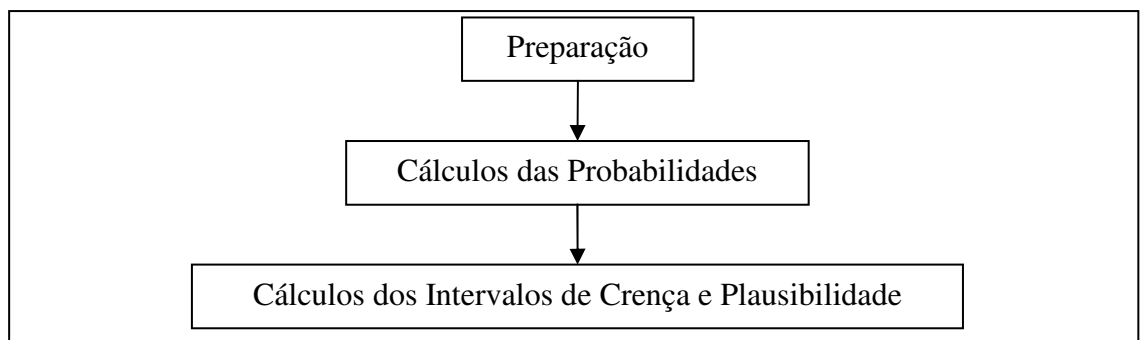


Figura 12. Modelagem do MI

A preparação consiste na análise das informações provenientes da base de conhecimento para verificação de dados inconsistentes, como, por exemplo, os valores das crenças dos especialistas e a quantidade de especialistas. Os cálculos das probabilidades são efetuados após essa verificação, bem como os cálculos dos intervalos de crença e plausibilidade.

O motor de inferência foi desenvolvido baseando-se nos diagramas ilustrados nas Figuras 11 e 12 e a partir de sua modelagem foi possível a implementação do *software*.

5.4 MODELAGEM E IMPLEMENTAÇÃO DO *SOFTWARE*

A Figura 11 ilustra as partes do módulo da TDS que foram desenvolvidas à *shell* Pegasus. Durante a implementação do MI foi criada uma interface gráfica para auxiliar a entrada de dados da BC, que é composta de hipóteses e evidências, e por meio dessas informações o MI efetua os cálculos e assim, apresenta os resultados.

O desenvolvimento foi realizado em Java por ser uma linguagem portátil⁴⁴ muito utilizada no meio acadêmico, com a utilização do ambiente de desenvolvimento NetBeans IDE 6.0.1⁴⁵ por ser uma ferramenta gratuita, e modelado por meio de diagramas UML⁴⁶ por representar um padrão internacional.

Como o *software* foi modelado para utilização do paradigma de orientação a objetos em virtude de características próprias da linguagem Java (LACERDA;

⁴⁴ Independe de plataforma, assim o programa desenvolvido em um sistema operacional pode ser executado em qualquer outro sistema (BITTENCOURT; OSÓRIO, 2001).

⁴⁵ O NetBeans IDE 6.0.1 é um ambiente de desenvolvimento Java baseada no *software* do netbeans.org, e é licenciado sobre a *Common Development and Distribution License* (CDDL) e a *GNU General Public License* versão 2 com exceção do *Classpath*. Disponível para *download* em <www.netbeans.org> (SUN MICROSYSTEMS, 2008).

⁴⁶ *Unified Modeling Language* (UML) está em desenvolvimento desde 1994. É um conjunto de técnicas para modelagem, retiradas de diversas metodologias, utilizadas para o desenvolvimento de sistemas (PENDER, 2004).

ZAVALIK, 2001), com exceção da classe da interface, as demais possuem métodos construtores⁴⁷ e os métodos de acesso *get* e *set*⁴⁸ para todos os atributos.

Os casos de uso e as classes são apresentados nos diagramas descritos a seguir gerados no próprio ambiente de desenvolvimento utilizado. A Figura 13 ilustra o diagrama de casos de uso.

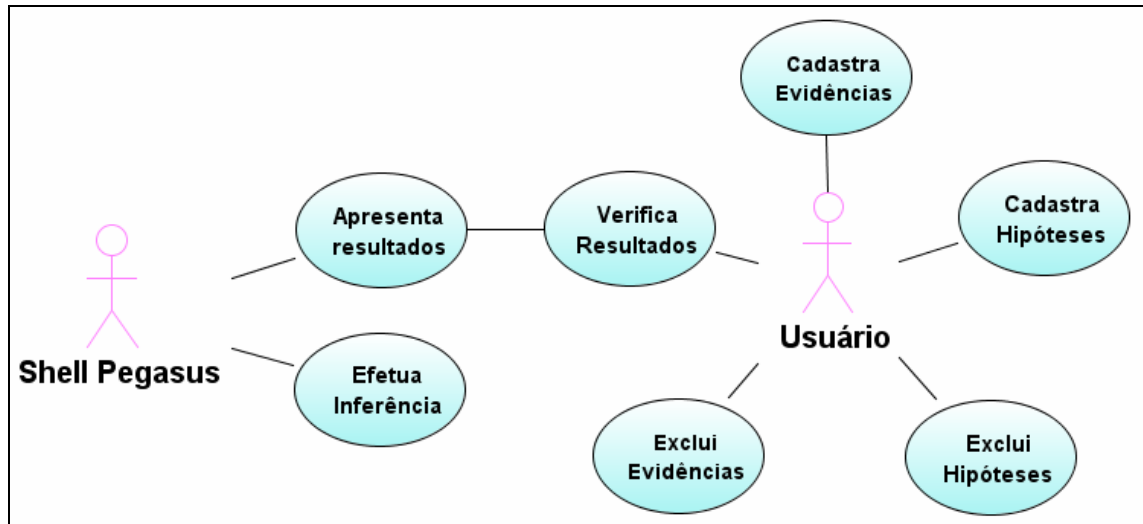


Figura 13. Diagrama de Casos de Uso

A Figura 14 ilustra o diagrama de classes sem as operações (métodos). As classes apresentadas são: *Hipotesys* (contém as informações sobre as hipóteses), *Evidence* (contém as informações sobre as evidências), *Evidences* (contém as informações sobre a lista das evidências) e *Inference* (contém as informações sobre a combinação das evidências).

⁴⁷ Os construtores possuem o mesmo nome da classe e são responsáveis pela criação dos objetos dessa classe (SUN MICROSYSTEMS, 2008).

⁴⁸ Os métodos *get* e *set* servem, respectivamente, para recuperar as informações de um determinado atributo de um objeto e gravá-las informações em um atributo de um determinado objeto (SUN MICROSYSTEMS, 2008).

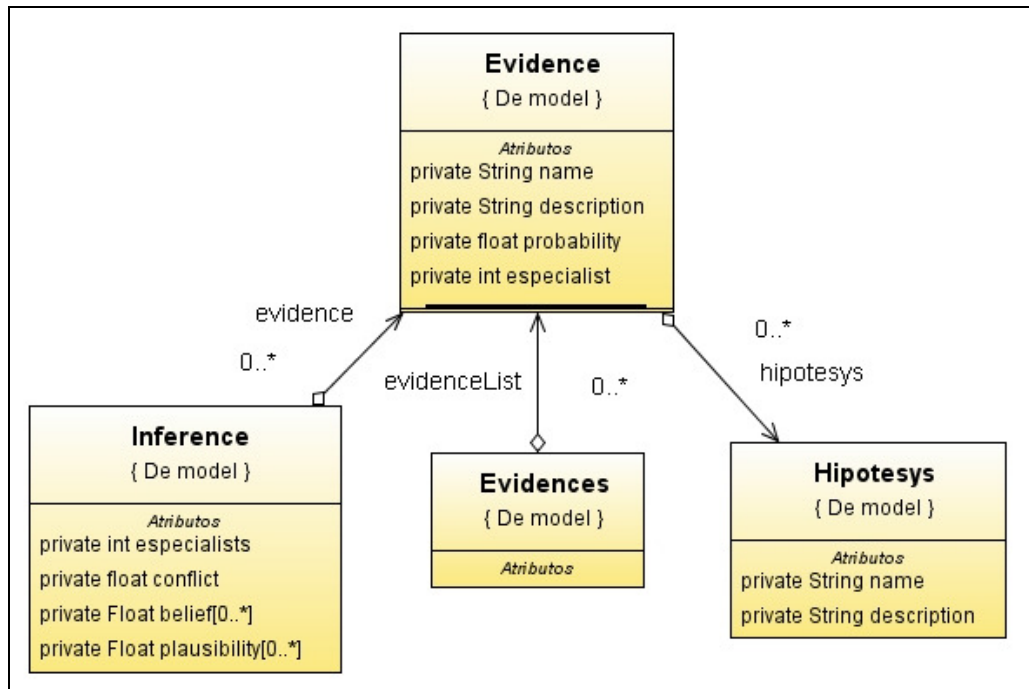
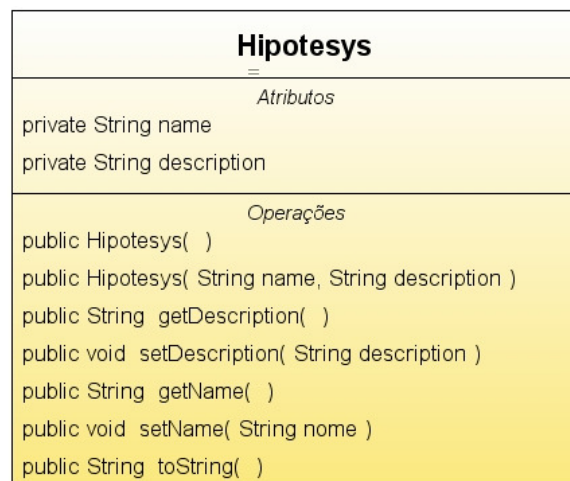


Figura 14. Diagrama de Classes

5.4.1 Classe *Hipotesys*

Esta classe contém as informações referentes às hipóteses da BC sendo composta pelos atributos que identificam a hipótese, como o nome e a descrição, os métodos de acesso aos atributos e os métodos construtores, conforme ilustra a Figura 15.

Figura 15. Classe *Hipotesys*

As Figuras 16 e 17 descrevem alguns conceitos do paradigma da orientação a objetos. Os métodos construtores são apresentados na Figura 16 contendo a lógica padrão para sua utilização a partir do paradigma de orientação a objetos.

```
public Hipotesys( )  
public Hipotesys( String name, String description )
```

Figura 16. Construtores da classe *Hipotesys*

Os métodos de acesso padrão aos atributos são apresentados na Figura 17.

```
public String getDescription( )  
public void setDescription( String description )  
public String getName( )  
public void setName( String nome )
```

Figura 17. Métodos de acesso aos atributos da classe *Hipotesys*

5.4.2 Classe *Evidence*

A classe *Evidence* é composta dos atributos que identificam a evidência como o nome da evidência, sua descrição, sua probabilidade e o número do especialista que identificou a evidência. Além dos atributos também são apresentados os métodos de acesso e os construtores, conforme ilustra a Figura 18.

| Evidence | |
|--|--|
| <i>Atributos</i> | |
| private String name | |
| private String description | |
| private float probability | |
| private int specialist | |
| <i>Operações</i> | |
| public Evidence() | |
| public Evidence(String name, String description, Hipotesys hipotesys[0..*], float probability, int specialist) | |
| public int getEspecialist() | |
| public void setEspecialist(int specialist) | |
| public String getDescription() | |
| public void setDescription(String description) | |
| public String getName() | |
| public void setName(String name) | |
| public float getProbability() | |
| public void setProbability(float probability) | |
| public Hipotesys[0..*] getHipotesys() | |
| public void setHipotesys(Hipotesys hipotesys[0..*]) | |

Figura 18. Classe *Evidence*

5.4.3 Classe *Evidences*

A classe *Evidences* é composta de um atributo que identifica a lista das evidências, dos métodos construtores, de métodos de acesso e diversos métodos responsáveis, principalmente, pela preparação da inferência (tratando inconsistências encontradas nos valores das crenças dos especialistas e na quantidade de especialistas) e cálculo e representação das probabilidades, conforme ilustra a Figura 19.

| Evidences | |
|---|--|
| <i>Atributos</i> | |
| <i>Operações</i> | |
| public Evidences() | |
| public Evidences(Evidence evidenceList[0..*]) | |
| public Evidence[0..*] getEvidenceList() | |
| public void setEvidenceList(Evidence evidenceList[0..*]) | |
| public float sumProbability(int specialistSelected) | |
| public Evidences inferenceBegin() | |
| public Evidences newSpecialistsInference(int specialistNumber, Evidences evidenceListAux) | |
| public boolean beforeInference(int specialistNumber) | |

Figura 19. Classe *Evidences*

O método *sumProbability* retorna o valor da soma das *bpa* do especialista selecionado, sendo essencial para a preparação da inferência, pois auxilia na determinação da consistência das informações.

O método *beforeInference* é utilizado na preparação da inferência na qual são verificados os valores das *bpa* de todos os especialistas. Esse método representa a codificação da fórmula 3 (Capítulo 3, Item 2):

$$\sum_{A \in 2^{\theta}} m(A) = 1$$

Caso o valor da soma das *bpa* de algum especialista não resulte 1, o retorno da função será falso e uma mensagem de alerta será exibida ao usuário.

O método *inferenceBegin* inicia o processo de inferência após a preparação realizada pelos dois métodos anteriores. Ele retorna um objeto do tipo *Evidences* contendo uma lista auxiliar com informações dos cálculos das probabilidades dos dois primeiros especialistas. Nesse cálculo é utilizada inicialmente a fórmula 9 (Capítulo 3, Item 6):

$$m_n(Z) = \sum_{X \cap Y = Z} m_{n-2}(X) m_{n-1}(Y)$$

Com a lista auxiliar formada, verifica-se a existência de outros especialistas no sistema, e em caso afirmativo o método *newSpecialistsInference* é chamado para efetuar o cálculo das probabilidades de todos os especialistas.

Este método recebe também a lista auxiliar e o número de especialistas retornando um objeto do tipo *Evidences* que contém uma lista com as informações da crença combinada de todos os especialistas. Esse método também utiliza para o cálculo a fórmula 9 (Capítulo 3, Item 6).

5.4.4 Classe *Inference*

A classe *Inference* é composta dos atributos que identificam a inferência como a quantidade de especialistas, o valor do peso de conflito e o intervalo de crença e plausibilidade. Além dos atributos também são apresentados os métodos de acesso, os construtores, e diversos métodos utilizados para realização da inferência, conforme ilustra a Figura 20.

| Inference |
|---|
| <i>Atributos</i> |
| <pre>private int especialistas private float conflict private Float belief[0..*] private Float plausibility[0..*]</pre> |
| <i>Operações</i> |
| <pre>public Inference() public Inference(int especialistas, float conflict) public Float[0..*] getBelief() public void setBelief(Float belief[0..*]) public Float[0..*] getPlausibility() public void setPlausibility(Float plausibility[0..*]) public Evidence[0..*] getEvidence() public void setEvidence(Evidence evidence[0..*]) public int getEspecialists() public void setEspecialists(int especialistas) public float getConflict() public void setConflict(float conflict) public Inference inferenceCalc(Evidences evidenceListAux) public Inference setBeliefAndPlausibilityInterval() public Inference renameEvidencesOfInference(Evidences evidenceList) public Inference inference(Evidences evidenceList, int specialistNumber)</pre> |

Figura 20. Classe *Inference*

O método *inferenceCalc* é responsável por efetuar os cálculos do peso de conflito e da combinação das crenças.

Durante a combinação das crenças são somadas as probabilidades das evidências que possuem o mesmo conjunto de hipóteses e, caso existam evidências com conjuntos de hipóteses vazios, a crença é normalizada.

As fórmulas utilizadas para o cálculo do peso de conflito são respectivamente, a 10 e a 11 (Capítulo 3, Item 7), tendo-se:

$$con(bel_1, bel_2) = \log(\chi) \qquad \chi = 1 / (1 - \kappa)$$

E a combinação das crenças é calculada por meio da utilização da fórmula 8 (Capítulo 3, Item 4):

$$m_n(Z) = \frac{\sum_{X \cap Y = Z} m_{n-2}(X) m_{n-1}(Y)}{1 - \sum_{X \cap Y = \emptyset} m_{n-2}(X) m_{n-1}(Y)}$$

Durante o cálculo do peso de conflito, caso seu valor ultrapasse 0.6, é exibida uma mensagem de aviso ao usuário.

O método *setBeliefAndPlausibilityInterval* calcula o intervalo de crença e plausibilidade, finalizando dessa maneira os passos executados pelo MI, conforme ilustra a Figura 12.

O método *inference* recebe a lista com as evidências e o número de especialistas e organiza todos os passos da inferência.

O método *renameEvidencesOfInference* é responsável por preparar as informações a serem apresentadas ao usuário renomeando as evidências resultantes da inferência a partir dos nomes constantes na lista de evidências.

5.4.5 Classe Interface

Além das classes apresentadas anteriormente, foi implementada uma classe para representação da interface (Apêndice A).

Os resultados obtidos com o desenvolvimento do *software*, juntamente com a descrição da interface são descritos a seguir.

5.4.6 Interface do Aplicativo

A interface gráfica com o usuário se encontra dividida nos quatro passos destacados no pseudocódigo da Figura 21.

```
*** TDS ***  
Início  
    Cadastra_Hipóteses;  
    Cadastra_Evidências;  
    Inferência;  
    Mostra_Resultados;  
Fim  
  
*** Inferência ***  
Início  
    Preparação;  
    Calcula_Probabilidades;  
    Calcula_Intervalos;  
Fim
```

Figura 21. Pseudocódigo

A Figura 22 ilustra a interface destacando cada passo do pseudocódigo.

SHELL PEGASUS - TDS

Hipóteses

Hipóteses [nome - descrição]

[A - Artrite]
 [AR - Artrite Reumatoide]
 [EA - Espondilite Anquilosante]
 [E - Espondilolistese]
 [HD - Hernia Discal]
 [LM - Lombalgia Muscular]
 [O - Outros tipos de lombalgia]

Nome: AR
 Descrição: Artrite Reumatoide

Cadastra_Hipóteses (Passo 1)

Carregar Salvar Remover Gravar

Evidências

Número de Especialistas: 3 Total de Crença do Especialista: 2 1.0

Evidências [nome - especialista - crença]

[LM - 1 - 0,518]
 [Domínio - 1 - 0,482]
 [A - 2 - 0,594]
 [Domínio - 2 - 0,406]
 [A - 3 - 0,594]
 [AR - 3 - 0,172]
 [LM - 3 - 0,129]

Nome: A Valor: 0.594
 Descrição: Hipóteses: [A - Artrite]

Cadastra_Evidências (Passo 2)

Carregar Salvar Remover Gravar

Combinar Evidências Inferência (Passo 3)

Resultados

| Nome | Probabilidade | Crença | Plausibilidade |
|---------|---------------|--------|----------------|
| A | 0,711 | 0,711 | 0,757 |
| AR | 0,076 | 0,076 | 0,122 |
| LM | 0,167 | 0,167 | 0,213 |
| Domínio | 0,046 | 1,000 | 1,000 |

Peso de Conflito: 0,192

Gráficos Fechar

Hipóteses: [[LM - Lombalgia muscular]]

Mostra_Resultados (Passo 4)

Figura 22. Interface

5.4.6.1 Definição da Base de Conhecimento

A base de conhecimento é definida por meio de dois passos apresentados no pseudocódigo (Figura 21): o *Cadastra_Hipóteses* (passo 1) e o *Cadastra_Evidências* (passo 2). O passo 1 é realizado por meio da parte da interface ilustrada na Figura 23.

Interface de manutenção da lista de hipóteses. O formulário contém o título "Hipóteses" e o subtítulo "Hipoteses [nome - descrição]". À esquerda, há uma lista vazia. À direita, há campos para "Nome:" e "Descrição:". Na base, há botões "Carregar", "Salvar", "Remover" e "Gravar".

Figura 23. Interface de manutenção da lista de hipóteses

Ao cadastrar uma hipótese é necessário preencher seu nome e sua descrição nos campos respectivos e selecionar a opção gravar. Deve-se levar em consideração que o atributo nome é obrigatório. A Figura 24 ilustra como funciona o procedimento.

Interface de manutenção da lista de hipóteses durante o cadastro. O campo "Nome:" contém o caractere "A" e o campo "Descrição:" contém o texto "Artrite". O botão "Gravar" está destacado com um retângulo vermelho.

Figura 24. Cadastro de hipóteses

O mesmo procedimento deve ser efetuado para cadastrar todas as demais hipóteses. Ao finalizar o passo 1 a lista de hipóteses apresenta todos os nomes e descrições das hipóteses, conforme ilustra a Figura 25.

Interface de manutenção da lista de hipóteses mostrando a lista final. A lista "Hipoteses [nome - descrição]" contém as seguintes entradas: "[A - Artrite]", "[HD - Hérnia Discal]", "[EA - Espondilite Anquilosante]", "[AR - Artrite Reumatoide]", "[E - Espondilolistese]", "[LM - Lombalgia Muscular]" e "[O - Outras]". O botão "Gravar" está destacado com um retângulo vermelho.

Figura 25. Lista das hipóteses

Durante a manutenção do passo 1 podem ser utilizadas as outras opções, como a de remover, que ao ser selecionada elimina a hipótese referente à seleção, a de

salvar, que ao ser escolhida efetua a criação de um arquivo texto contendo os dados da lista de hipóteses, e a opção carregar que efetua a leitura do arquivo texto e copia os dados para a lista de hipóteses.

O passo 2 é realizado por meio da parte da interface ilustrada na Figura 26.

Figura 26. Interface de manutenção da lista de evidências

Durante o cadastro de uma evidência é necessário primeiramente preencher a quantidade de especialistas, em seguida, o número do especialista que observou a evidência, o nome da evidência, sua descrição, o valor da crença atribuída pelo especialista e as hipóteses relacionadas à evidência nos campos respectivos e selecionar a opção gravar.

Ao selecionar esta opção devem ser levadas em consideração quatro premissas:

- a) o campo correspondente ao número de especialistas deve ser preenchido para que possam ser escolhidos os especialistas das evidências a serem cadastradas;
- b) o especialista a ser cadastrado deve ser selecionado previamente;
- c) os campos referentes ao nome da evidência, valor da crença, número do especialista e hipóteses são obrigatórios;
- d) para adicionar as hipóteses à lista de hipóteses relacionadas a evidência, devem ser escolhidas as previamente cadastradas.

A Figura 27 ilustra como funciona o procedimento do cadastro de evidências.

Hipóteses
 Hipoteses [nome - descrição]
 [A - Artrite]
 [AR - Artrite Reumatoide]
 [EA - Espondilite Anquilosante]
 [E - Espondilolistese]
 [HD - Hernia Discal]
 [LM - Lombalgia Muscular]
 [O - Outros tipos de lombalgia]

Nome: LM
 Descrição: Lombalgia Muscular

Carregar Salvar Remover Gravar

Evidências
 Número de Especialistas: 3 Total de Crença do Especialista: 1 0.0

Evidencias [nome - especialista - crença]

Nome: LM Valor: 0.129
 Descrição: Hipoteses: [LM - Lombalgia Muscular]

Carregar Salvar Remover Gravar

Ao selecionar a hipótese ela é inserida automaticamente.

Figura 27. Cadastro de evidências

O mesmo procedimento deve ser efetuado para cadastrar todas as demais evidências. Ao finalizar o passo 2, a lista de evidências apresenta as informações cadastradas, conforme ilustra a Figura 28.

Evidências
 Número de Especialistas: 3 Total de Crença do Especialista: 1 1.0

Evidencias [nome - especialista - crença]

[LM - 1 - 0,518]
 [Domínio - 1 - 0,482]
 [A - 2 - 0,594]
 [Domínio - 2 - 0,406]
 [A - 3 - 0,594]
 [AR - 3 - 0,172]
 [LM - 3 - 0,129]

Nome: Valor:
 Descrição: Hipoteses:

Carregar Salvar Remover Gravar

Figura 28. Lista das evidências cadastradas exibidas na interface

Pode-se ressaltar ainda que ao selecionar uma evidência suas informações são apresentadas, conforme ilustra a Figura 29. No exemplo é selecionada a evidência referente à lombalgia muscular (LM), apresentando os seus respectivos dados.

Figura 29. Seleção de um item da lista das evidências para exibição das informações

Durante a manutenção do passo 2 podem ser utilizadas as outras opções, como a opção remover, que ao ser selecionada elimina a evidência referente à seleção e a opção salvar, que ao ser selecionada efetua a criação de um arquivo texto contendo os dados da lista de evidências.

A partir do cadastro da lista das evidências, a base de conhecimento é finalizada, sendo possível a partir deste momento efetuar a inferência (passos 3 e 4).

5.5 TESTES

Os testes foram realizados baseando-se na modelagem matemática apresentada no Capítulo 5, Item 2. Sendo o domínio do problema abrangendo $\Theta =$ (Artrite {A}, Hérnia Discal {HD}, Espondilite Anquilosante {EA}, Artrite Reumatoide {AR}, Espondilolistese {E}, Lombalgia Muscular {LM}, Outras {O}) foi efetuada a inserção das informações no módulo da TDS na *shell* Pegasus.

A fim de verificar a precisão dos cálculos realizados na *shell* Pegasus, o mesmo teste foi efetuado na ferramenta Dempster-Shafer Engine (Capítulo 4, Item 2,

Subitem 1), que foi escolhida por ser referenciada entre os trabalhos correlatos desta pesquisa, assim o cadastro das hipóteses em ambas as ferramentas é ilustrado na Figura 35.

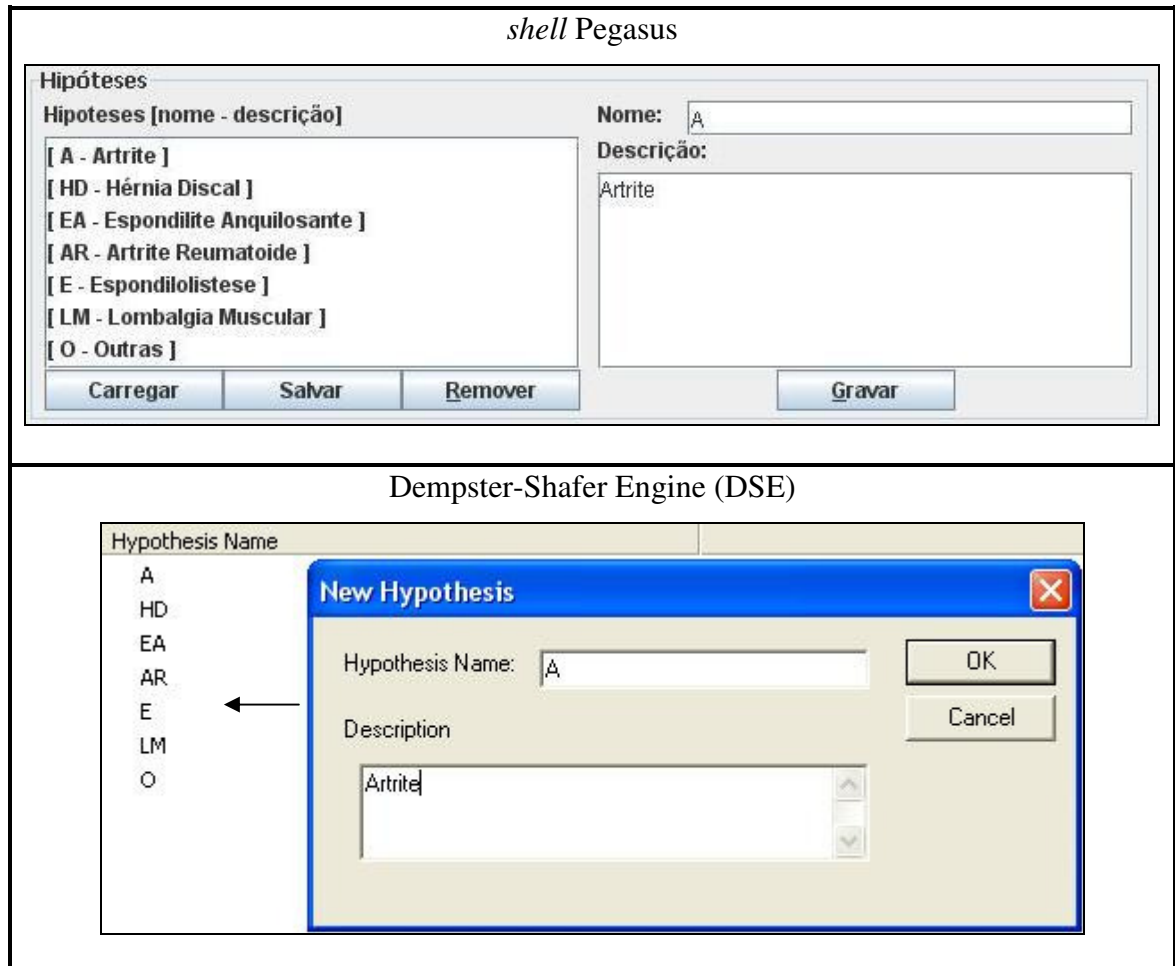


Figura 30. Cadastro das hipóteses na *shell Pegasus* e na ferramenta DSE

Conforme apresentado anteriormente, após o cadastro das hipóteses, é necessário efetuar a inserção das evidências dos especialistas. Assim, a Figura 36 ilustra as evidências selecionadas pelos 3 especialistas cadastradas na *shell Pegasus*.

Figura 31. Cadastro das evidências

Na ferramenta DSE, antes de efetuar o cadastro das evidências é necessário adicionar os especialistas por meio da opção ilustrada na Figura 37.

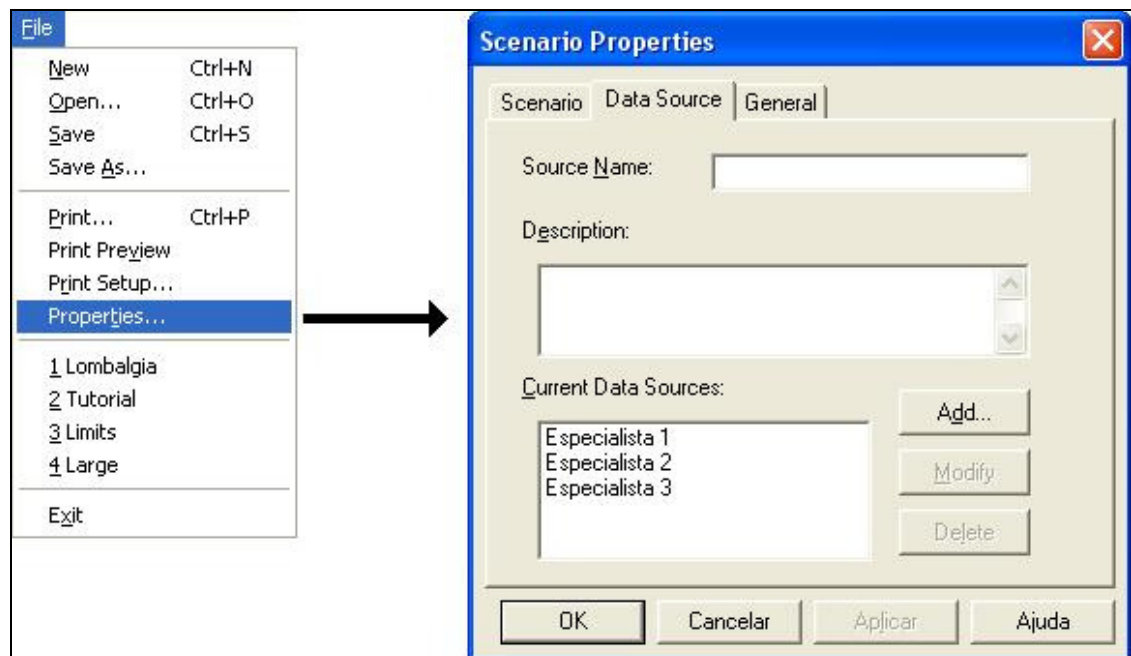


Figura 32. Cadastro dos especialistas na ferramenta DSE

O cadastro das evidências é concluído por meio dos passos descritos na Figura 38.

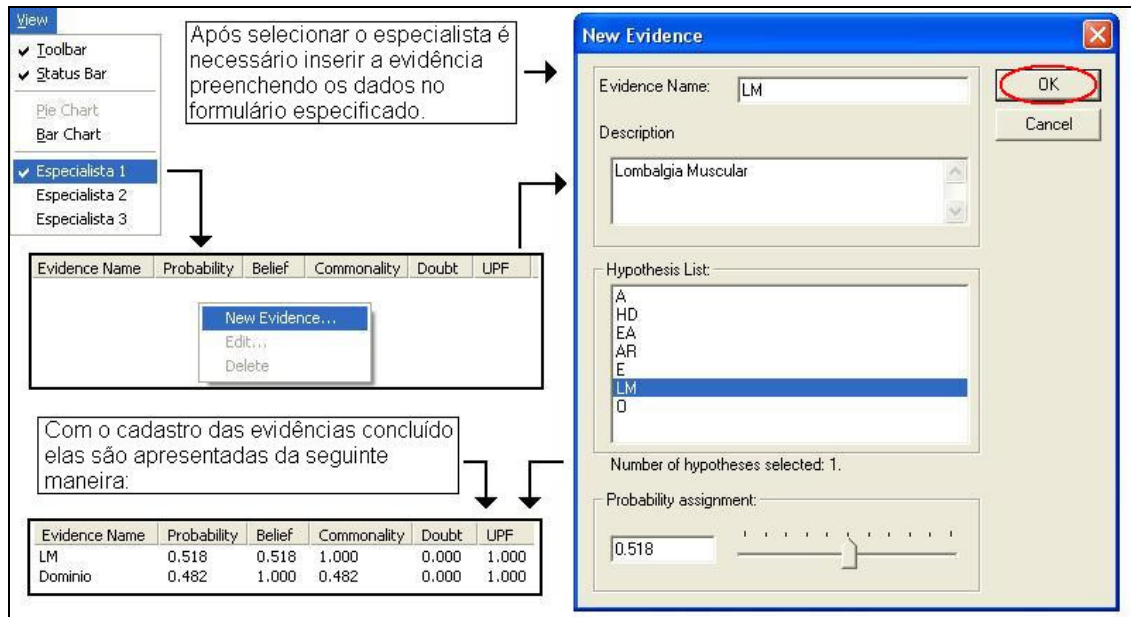


Figura 33. Cadastro das evidências na ferramenta DSE

Com todas as hipóteses e evidências cadastradas é possível prosseguir com a combinação das evidências dos especialistas. Na *shell* Pegasus essa combinação é efetuada por meio da opção ilustrada na Figura 39.



Figura 34. Combinação das evidências

Apresentando o resultado ilustrado na Figura 40.

| Nome | Probabilidade | Crença | Plausibilidade |
|---------|---------------|--------|----------------|
| A | 0,711 | 0,711 | 0,757 |
| AR | 0,076 | 0,076 | 0,122 |
| LM | 0,167 | 0,167 | 0,213 |
| Domínio | 0,046 | 1,000 | 1,000 |

Hipóteses: [[A - Artrite]]

Peso de Conflito: 0,192

Fechar

Figura 35. Resultados da combinação das evidências dos especialistas

Na ferramenta DSE a combinação das evidências é efetuada por meio da opção representada pelo símbolo Σ , cujos resultados são apresentados na Figura 41.

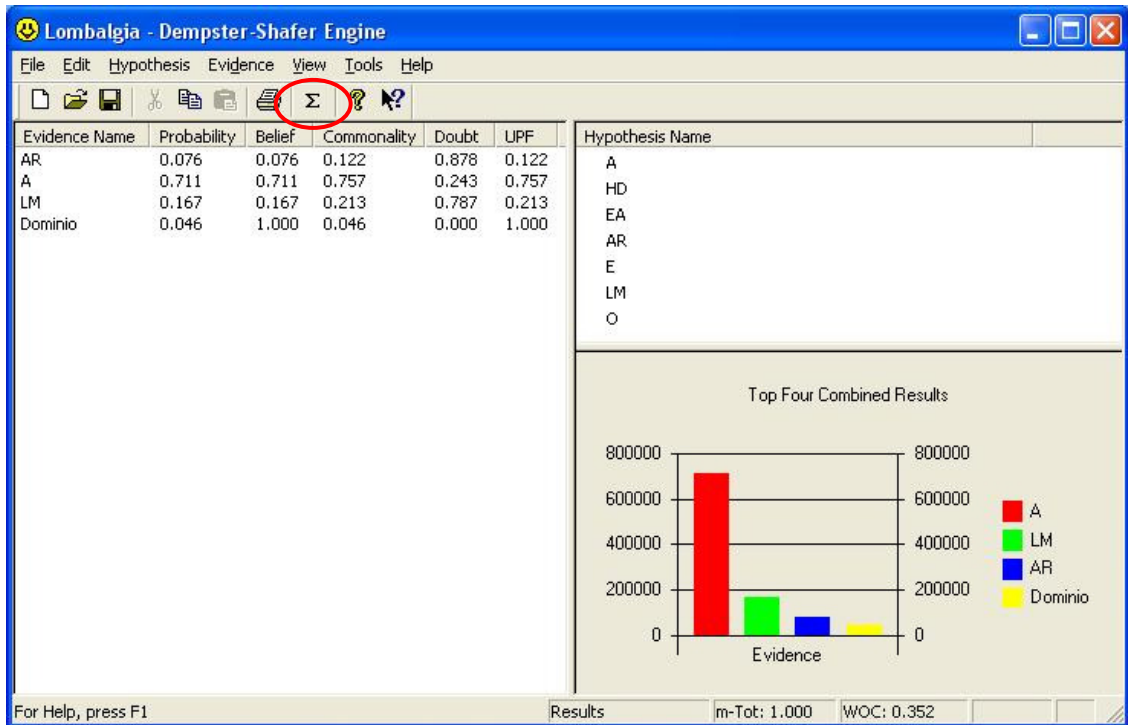


Figura 36. Resultados da combinação das evidências dos especialistas na DSE

Conforme verificado durante os testes todos os valores são semelhantes, fundamentados pelos formalismos da TDS.

5.6 RESULTADOS OBTIDOS

Esta pesquisa resultou em um módulo da *shell* Pegasus voltado à inferência baseada no formalismo matemático da teoria de Dempster-Shafer apresentada nos capítulos e itens anteriores.

A combinação de evidências é definida por meio de dois passos apresentados no pseudocódigo (Figura 21): Inferência (passo 3) e o Mostra_Resultados (passo 4). O passo 3 é realizado por meio da seleção da opção de combinação das evidências conforme ilustra a Figura 30.



Figura 37. Botão da inferência

Ao selecionar esta opção, os métodos indicativos do processo de inferência são executados, e o resultado é informado conforme ilustra a Figura 31, que apresenta o painel dos resultados, sendo esse o passo 4.

| Resultados | | | |
|------------|---------------|--------|----------------|
| Nome | Probabilidade | Crença | Plausibilidade |
| A | 0,711 | 0,711 | 0,757 |
| AR | 0,076 | 0,076 | 0,122 |
| LM | 0,167 | 0,167 | 0,213 |
| Domínio | 0,046 | 1,000 | 1,000 |

Peso de Conflito: 0,192

Gráficos

Fechar

Hipóteses:

Figura 38. Interface dos resultados da inferência

Essa parte da interface apresenta uma tabela descrevendo os detalhes dos resultados. Na primeira coluna são apresentados os nomes das evidências resultantes da combinação das crenças; na segunda coluna são apresentados os valores das *bpa* referentes às evidências; e nas outras duas colunas são representados os intervalos de crença e plausibilidade que apresentam as faixas de valores nas quais é possível acreditar nas evidências, sem que ocorram erros de suposição.

O passo 4 também apresenta o valor do peso de conflito no qual pode ser verificado se os resultados são confiáveis.

Nessa parte da interface também é possível verificar as hipóteses das evidências. Ao clicar em alguma linha da tabela, as hipóteses são apresentadas no campo específico, conforme ilustra a Figura 32.

| Resultados | | | |
|------------|---------------|--------|----------------|
| Nome | Probabilidade | Crença | Plausibilidade |
| A | 0,711 | 0,711 | 0,757 |
| AR | 0,076 | 0,076 | 0,122 |
| LM | 0,167 | 0,167 | 0,213 |
| Domínio | 0,046 | 1,000 | 1,000 |

Peso de Conflito: 0,192

Gráficos

Fechar

Hipóteses: [[A - Artrite]]

Figura 39. Hipóteses na interface dos resultados da inferência

Ao clicar na tabela, além das hipóteses, também é apresentado o gráfico correspondente aos valores da probabilidade e do intervalo de crença e plausibilidade da

linha selecionada, conforme ilustra a Figura 33, onde o nome da evidência encontra-se destacado no canto superior esquerdo da imagem.

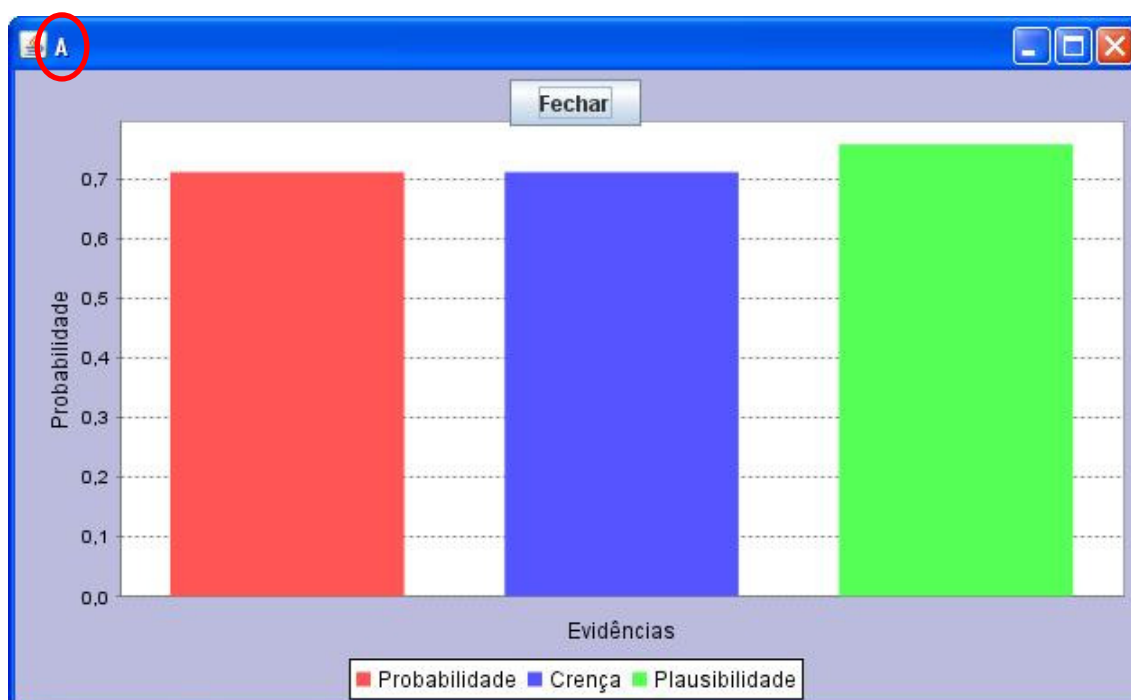


Figura 40. Gráfico dos Resultados

Outra característica da apresentação dos resultados é a geração de gráficos comparativos das evidências resultantes. Ao selecionar a opção Gráficos a Figura 34 é apresentada ao usuário, ilustrando a probabilidade de cada crença combinada.

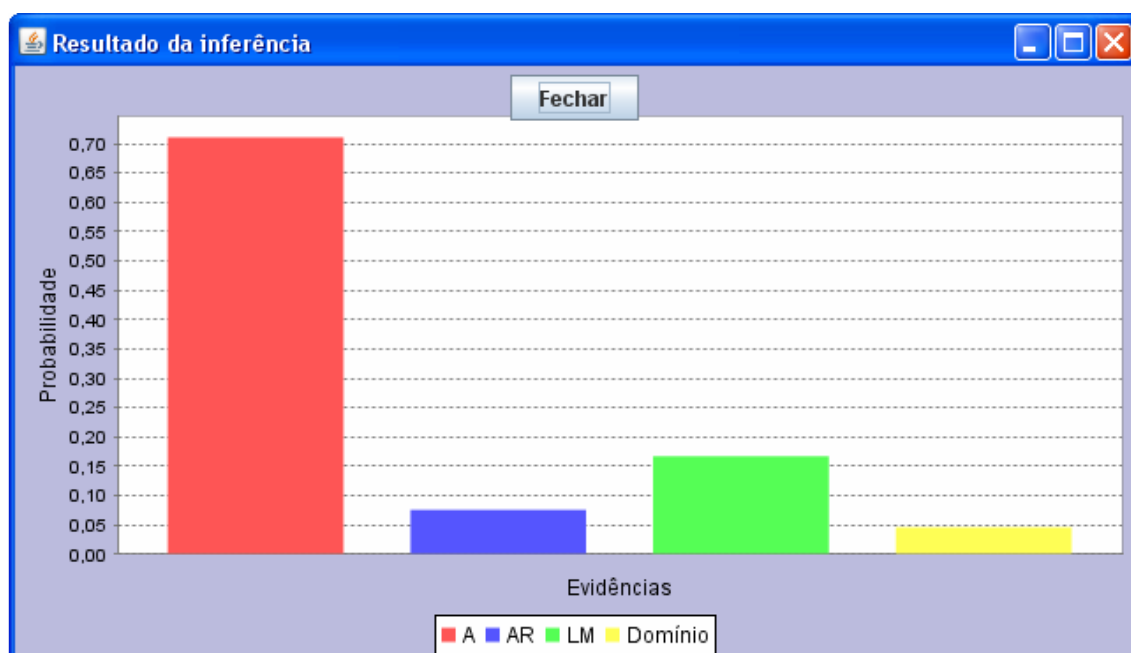


Figura 41. Gráfico Comparativo dos Resultados

Assim, o aplicativo, referente ao módulo da TDS na *shell* Pegasus, oferece além do motor de inferência, uma interface com o usuário que o auxilia no cadastro das informações na base de conhecimento e também apresenta de forma sucinta as informações referentes à execução da inferência.

CONCLUSÃO

Durante a utilização de um sistema especialista costuma-se observar que o conhecimento pode estar inconsistente gerando conclusões conflitantes, ou ainda incompleto, sem as informações necessárias para se chegar a uma conclusão adequada. Devido a carência de uma teoria genérica que consiga modelar todos os tipos de incerteza, a escolha de um método para a sua representação no motor de inferência é um problema rotineiro enfrentado durante o desenvolvimento dos sistemas especialistas.

Assim, esta pesquisa demonstrou o processo de inferência por meio dos formalismos matemáticos da teoria de Dempster-Shafer na *shell Pegasus Uncertainty Modeling*, que além desta teoria abrange a lógica *fuzzy*, as redes bayesianas e os fatores de certeza.

Durante o levantamento bibliográfico foi compreendido o processo de construção de SE e sua utilidade no meio científico em diversas áreas, como na saúde. Para entender o funcionamento de um SE estudou-se sobre o desenvolvimento do motor de inferência, sendo este o seu módulo principal.

Desse modo, sendo a modelagem da incerteza uma forma de representar a máquina de inferência, foram estudadas algumas técnicas para essa finalidade, dando enfoque à teoria da evidência de Dempster-Shafer.

Conforme apresentado nesta pesquisa, a TDS é uma técnica voltada ao tratamento da incerteza por ignorância e utilizada para o desenvolvimento do motor de inferência no respectivo módulo da *shell Pegasus*.

Ao utilizar esta teoria foram compreendidos seus formalismos e por meio deles, apresentada a modelagem matemática, aplicada ao diagnóstico de lombalgia, que

contou com conhecimentos do especialista em Ortopedia e Traumatologia, Robson Luiz dos Santos, que faz parte do corpo docente do curso de Medicina da UNESC.

A partir da modelagem matemática realizou-se a modelagem do sistema em UML, seguindo-se com a implementação que se deu na linguagem Java a partir do ambiente NetBeans IDE 6.0.1. O aplicativo resultante desta pesquisa corresponde então ao módulo da TDS que foi integrado à *shell* Pegasus, que oferece as opções de cadastrar hipóteses e evidências e também de apresentar os resultados da inferência ao usuário.

Foram feitos alguns testes para determinar a precisão dos cálculos, os quais foram comparados com a ferramenta DSE. Os resultados foram satisfatórios demonstrando que os cálculos são semelhantes. Outra observação verificada foi a relativa simplicidade com que as informações são cadastradas na *shell* Pegasus comparado-se com a ferramenta DSE.

Sugere-se como trabalhos futuros:

- a) desenvolver modelos híbridos na *shell* Pegasus pela utilização de outras técnicas de modelagem da incerteza juntamente com a TDS, como as redes bayesianas e os fatores de certeza;
- b) tornar o peso de conflito variável;
- c) realizar um projeto de interface abrangendo questões de ergonomia de software;
- d) implementar representações da TDS desenvolvidas por outros autores como a nova regra de Campos (2005) e o método de combinação modificado de Yager e Inagaki (WU, 2003).

REFERÊNCIAS

BADIRU, A. B.; CHEUNG, J. Y. **Fuzzy engineering expert systems with neural network applications**. New York: J. Wiley, 2002.

BIANCHI, R. A. C. **Uma Arquitetura de Controle Distribuída para um Sistema de Visão Computacional Propositada**. 1998. 104 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade de São Paulo, São Paulo, 1998. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/3/3142/tde-10122004-222058/publico/bianchi-MsC.pdf>>. Acesso em: 01 maio 2008.

BITTENCOURT, G. **Inteligência artificial: ferramentas e teorias**. 2.ed. Florianópolis: UFSC, 2001.

BITTENCOURT, J. R.; OSÓRIO, F. ANNEF – Artificial Neural Networks Framework: Uma Solução Software Livre Para o Desenvolvimento, Ensino e Pesquisa de Aplicações de Inteligência Artificial Multiplataforma. In: Fórum Internacional de Software Livre, 2., 2001, Porto Alegre. **Anais eletrônicos...** São Leopoldo, RS: Universidade do Vale do Rio dos Sinos, 2001. p. 13-16. Disponível em: <<http://www.ulbra.tche.br/wsl2001/anais.pdf#page=22>>. Acesso em: 02 jun. 2008.

BUCHANAN, B. G.; SHORTLIFFE, E. H. **Rule-based Expert Systems: The MYCIN Experiments of the Stanford Heuristic Programming Project**. Reading, Massachusetts: Addison-Wesley Publishing Company, 1984. Disponível em: <<http://www.aai.org/AITopics/classic/buchanan.html>>. Acesso em: 10 set. 2007.

CALILI, R. F. **Desenvolvimento de sistema para detecção de perdas comerciais em redes de distribuição de energia elétrica**. 2005. 157 f. Dissertação (Mestrado em Engenharia Elétrica) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005. Disponível em: <http://www.maxwell.lambda.ele.puc-rio.br/cgi-bin/db2www/PRG_0490.D2W/INPUT?CdLinPrg=pt>. Acesso em: 12 set. 2007.

CAMPOS, F. **Uma Extensão à Teoria Matemática da Evidência**. 2005. 119 f. Tese (Doutorado em Ciência da Computação) – Universidade Federal de Pernambuco, Recife, 2005. Disponível em: <http://www.bdtd.ufpe.br/tedeSimplificado//tde_busca/arquivo.php?codArquivo=564>. Acesso em: 18 mar. 2008.

CARVALHO, K. D. **Representação de Conhecimento Usando a Teoria de Dempster-Shafer**. 2001. Monografia de Graduação – Faculdade de Ciência da Computação, Universidade Federal de Lavras, Lavras, MG, 2001. Disponível em: <http://www.comp.ufla.br/monografias/ano2001/Representacao_de_conhecimento_usando_a_teorias_de_Dempster_Shafer.pdf>. Acesso em: 14 out. 2007.

COLTRI, P. P. **Influência do uso e cobertura do solo no clima de Piracicaba, SP: análise de séries históricas, ilhas de Calor e técnicas de sensoriamento remoto**. 2006. Dissertação (Mestrado em Fitotecnia) – Universidade de São Paulo, São Paulo, SP, 2006. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/11/11136/tde-25102006-123617/>>. Acesso em: 11 mar. 2008.

COSTA, E.; SIMÕES, A. **Inteligência Artificial: fundamentos e aplicações**. Lisboa: FCA, 2004.

COX, E. **Fuzzy modeling and genetic algorithms for data mining and exploration**. California: Morgan Kaufmann, 2005.

DARTMOUTH COLLEGE COMPUTATION CENTER. **BASIC: A Manual for BASIC, the Elementary Algebraic Language Designed for Use with the Dartmouth Time Sharing System**. Hanover: Trustees of Dartmouth College, 1964. Disponível em: <<http://www.reanimators.org/tmp/10027.pdf>>. Acesso em: 17 mar. 2008.

ENCICLOPAEDIA BRITANNICA. **Micropédia I**. Rio de Janeiro, 1997.

ENCICLOPAEDIA BRITANNICA. **Micropédia II**. Rio de Janeiro, 1997.

FERNANDES, A. M. R. **Inteligência Artificial: noções gerais**. Florianópolis: Visual Books, 2003.

GALVÃO, W. S.; MENESES, P. R. Uso do SIG e do classificador ISODATA na geração do mapa de regiões geoambientais homogêneas na bacia do rio São Francisco, como um produto estratégico de apoio às ações de planejamento de redes fluviométricas. In: Simpósio Brasileiro de Sensoriamento Remoto, 22., 2005, Goiânia. **Anais...** Goiânia, GO: Instituto Nacional de Pesquisas Espaciais, 2005. p. 2177-2184. Disponível em: <<http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.21.01.43/doc/2177.pdf>>. Acesso em: 11 mar. 2008.

GIARRATANO, J.; RILEY, G. **Expert systems: principles and programming**. Boston: PWS, 1998.

GOULART, J. P. **Utilização de um Agente Pedagógico para Acompanhamento do Processo de Ensino-Aprendizagem de Lombalgia no Sistema Especialista Probabilístico de Apoio ao Ensino do Diagnóstico Etiológico de Lombalgia.** 2007. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) - Universidade do Extremo Sul Catarinense, Criciúma, 2007.

GOULARTE, F. B. **SÉLO - Sistema Especialista Probabilístico de apoio ao ensino do diagnóstico etiológico de Lombalgia.** 2002. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) - Universidade do Extremo Sul Catarinense, Criciúma, 2002.

JAMES, B. R. **Probabilidade:** um curso em nível intermediário. Rio de Janeiro: Instituto de Matemática Pura e Aplicada, 1981.

LACERDA, G. S.; ZAVALIK, C. O Uso de Software Livre no Desenvolvimento de Aplicações Orientadas a Objetos para a Web. In: Fórum Internacional de Software Livre, 2., 2001, Porto Alegre. **Anais eletrônicos...** Porto Alegre, RS: Universidade Federal do Rio Grande do Sul, 2001. p. 5-8. Disponível em: <<http://www.ulbra.tche.br/wsl2001/anais.pdf#page=22>>. Acesso em: 02 jun. 2008.

LERSCH, R.; HAERTEL, V.; SHIMABUKURO, Y. Investigação sobre o uso de dados auxiliares no processo de classificação de imagens digitais empregando princípios da teoria da evidencia. In: Simpósio Brasileiro de Sensoriamento Remoto, 23., 2007, Florianópolis. **Anais...** São José dos Campos, SP: Instituto Nacional de Pesquisas Espaciais, 2007. p. 21-26. Disponível em: <http://www.ufrgs.br/srm/novo/publicacoes/SBSR%202007_Vitor%20Rodrigo%20Yosio_artigo.pdf>. Acesso em: 30 out. 2007.

LINDSAY, R. K.; BUCHANAN, B. G.; FEIGENBAUM, E. A.; LEDERBERG, J. **Applications of Artificial Intelligence for Organic Chemistry: The Dendral Project.** New York: McGraw-Hill, 1980. Disponível em: <http://profiles.nlm.nih.gov/BB/A/L/A/F/_/bbalaf.pdf>. Acesso em: 12 ago. 2007.

LUGER, G. F. **Inteligência artificial:** estruturas e estratégias para a resolução de problemas complexos. 4. ed. Porto Alegre: Bookman, 2004.

MOREIRA, L. C. J.; SOUZA, B. F. S.; COSTA, C. A. G.; TEIXEIRA, A. S.; VIANA, T. V. A.; NOBRE, J. G. A. Monitoramento da cobertura vegetal no desenvolvimento da mamona com uso do SIARCS e ENVI. In: In: Simpósio Brasileiro de Sensoriamento Remoto, 23., 2007, Florianópolis. **Anais...** Florianópolis, SC: Instituto Nacional de Pesquisas Espaciais, 2007. p. 293-297. Disponível em: <<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.16.00.56/doc/293-297.pdf>> Acesso em: 11 mar. 2008.

MURRAY, M. T. **Artrite: uma abordagem natural**. Rio de Janeiro: Campus, 1998.

NAKAMURA, E. F.; NAKAMURA, F. G.; FIGUEIREDO, C. M. S.; LOUREIRO, A. A. F. Detecção de Falhas em Redes de Sensores sem Fio Baseada na Medição do Tráfego e em Técnicas de Fusão de Dados. In: Simpósio Brasileiro de Redes de Computadores, 23., 2005, Fortaleza. **Anais...** Fortaleza, CE: Universidade Federal do Ceará, Universidade Estadual do Ceará, 2005. Disponível em: <<http://www.lbd.dcc.ufmg.br:8080/colecoes/sbrc/2005/041.pdf>>. Acesso em: 30 out. 2007.

NASA. **Landsat 7: Science Data Users Handbook**. Disponível em: <http://landsathandbook.gsfc.nasa.gov/handbook/handbook_toc.html> Acesso em: 10 mar. 2008.

O'NEILL, A. **Dempster-Shafer Engine**. Version 1.0. 1999. Disponível em: <<http://aonaware.com/dse.htm>>. Acesso em: 10 dez. 2007.

PEARL, J. **Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference**. San Francisco: Morgan Kauffmann, 1988.

PENDER, T. **UML: a Bíblia**. Rio de Janeiro: Elsevier, 2004.

PINTO, A. J. G. **Mecanismo de Agregação de Dados Empregando Técnicas Paramétricas em Redes de Sensores**. 2004. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2004. Disponível em: <<http://www.gta.ufrj.br/ftp/gta/TechReports/Antonio04/Antonio04.pdf>>. Acesso em: 12 jun. 2007.

QUEIROZ, R. B.; RODRIGUES, A. G.; GÓMEZ, A. T. Estudo Comparativo entre as Técnicas Máxima Verossimilhança Gaussiana e Redes Neurais na Classificação de Imagens IR-MSS CBERS 1. In: WorkComp Sul, 1., 2004, Palhoça. **Anais...** São Leopoldo: Universidade do Vale do Rio dos Sinos, 2004. Disponível em: <<http://inf.unisul.br/~ines/workcomp/cd/pdfs/2307.pdf>>. Acesso em: 17 mar. 2008.

REZENDE, S. O. **Sistemas inteligentes: fundamentos e aplicações**. Barueri: Manole, 2005.

RUSSEL, S. J.; NORVIG, P. **Inteligência artificial**. Rio de Janeiro: Elsevier, 2004.

SANTOS, R. L.; OHATA, A.T.; QUINTANILHA, J. A. A teoria da incerteza aplicada a classificação de imagens de satélite. In: Congresso Brasileiro de Cartografia, 21., 2003, Belo Horizonte. **Anais...** Belo Horizonte, MG, 2003. p 1-8. Disponível em: <http://www.cartografia.org.br/xxi_cbc/050-SR12.pdf>. Acesso em: 10 out. 2007.

SCUSSEL, T. **Base de Conhecimento para um Sistema Especialista de Apoio ao Diagnóstico Etiológico da Lombalgia**. 2001. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) - Universidade do Extremo Sul Catarinense, Criciúma, 2001.

SENTZ, K.; FERSON, S. **Combination of Evidence in Dempster-Shafer Theory**. SAND2002-0835 Technical Report. Sandia National Laboratories, Albuquerque, New Mexico, 2002. Disponível em: <<http://www.sandia.gov/epistemic/Reports/SAND2002-0835.pdf>>. Acesso em: 28 ago. 2007.

SILVA, J. D. S.; SIMONI, P. O. Dempster-Shafer Theory as an *Inference* Method for Corresponding Geometric Distorted Images. In: Encontro Nacional de Inteligência Artificial, 4., 2003, Campinas. **Anais...** Rio de Janeiro: Instituto Doris Aragon, 2003. p. 1-6. Disponível em: <<http://www.lac.inpe.br/~demisio/download/papers/enia2003paper670.pdf>>. Acesso em: 30 ago. 2007.

SOARES, P. C.; PERDONCINI, L. C. Incerteza e combinação de evidências: a questão dos diamantes do rio Tibagi-PR. **Revista Brasileira de Geociências**, São Paulo, v. 29, n. 3, p. 307-312, 1999. Disponível em: <http://www.sbgeo.org.br/rgb/vol29_down/2903/2903307.pdf>. Acesso em: 10 set. 2007.

STEWART, James. **Cálculo**. 5.ed. São Paulo: Thomson, 2006.

SUGUIO, K. **Rochas sedimentares**: propriedades, gênese, importância econômica. São Paulo: Edgard Blücher, 1980.

SUN MICROSYSTEMS. NetBeans. Disponível em: <www.netbeans.org>. Acesso em: 02 jun. 2008.

TALLEY, N. J.; O'CONNOR, S. **Exame clínico**: guia prático para o diagnóstico físico. 2.ed. Rio de Janeiro: Revinter, 2000.

THE MATHWORKS. **Mathlab**: The Language of Technical Computing. Disponível em: <<http://www.mathworks.com/products/matlab/>> Acesso em: 17 mar. 2008.

UCHÔA, J. Q.; PANOTIM, S. M.; NICOLETTI, M. C. **Elementos da Teoria de Dempster-Shafer**. Relatório do Departamento de Computação 007/97. São Carlos: DC-UFSCar, 1997. Disponível em: <<http://www.dc.ufscar.br/~carmo/relatorios/dempster.pdf>>. Acesso em: 10 ago. 2007.

VALDATI, L. P. **Utilização de um Agente Tutor em um Sistema de Apoio ao Ensino e Diagnóstico**. 2008. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) - Universidade do Extremo Sul Catarinense, Criciúma, 2008.

VIEIRA, P. R. **Desenvolvimento De Classificadores De Máxima Verossimilhança E Icm Para Imagens Sar**. 1996. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1996. Disponível em: <<http://www.dpi.inpe.br/dpi/teses/ronalt/ICM-PedroRV.pdf>>. Acesso em: 11 mar. 2008.

YAGER, R. R.; KACPRZYK, J.; FEDRIZZI, M. (Ed.). **Advances in the Dempster-Shafer theory of Evidence**. New York: John Wiley & Sons, 1994.

WU, H. **Sensor Data Fusion for Context-Aware Computing Using Dempster-Shafer Theory**. 2003. Tese (Doutorado de Filosofia em Robótica) – The Robotics Institute, Carnegie Mellon University, Pittsburgh, Pennsylvania. 2003. Disponível em: <<http://www.cs.cmu.edu/~whd/publications/whd-thesis.pdf>>. Acesso em: 25 out. 2007.

BIBLIOGRAFIA RECOMENDADA

CAMPOS, M. M.; SAITO, K. **Sistemas inteligentes em controle e automação de processos**. Rio de Janeiro: Ciência Moderna, 2004.

DEMPSTER, A. P. Upper and Lower Probabilities Induced by a Multivalued Mapping. **The Annals of Statistics**, Philadelphia, USA, v. 28, p. 325-339, 1967. Disponível em: <http://projecteuclid.org/DPubS/Repository/1.0/Disseminate?view=body&id=pdf_1&handle=euclid.aoms/1177698950>. Acesso em: 17 ago. 2007.

FLANAGAN, D. **Java: o guia essencial**. 3.ed. Rio de Janeiro: Campus, 2000.

KORB, K. B.; NICHOLSON, A. E. **Bayesian artificial intelligence**. Florida: Chapman & Hall, 2004.

LINARES, K. S. C. **Sistema Especialista Nebuloso para Diagnóstico Médico**. 1997. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Santa Catarina, Florianópolis, SC, 1997. Disponível em: <<http://www.inf.ufsc.br/~barreto/teses/dmkathya.pdf>>. Acesso em: 18 out. 2007.

NASCIMENTO JÚNIOR, C. L.; YONEYAMA, T. **Inteligência Artificial: em controle e automação**. São Paulo: FAPESP, 2000.

NICOLETTI M. C.; UCHÔA, J. Q. **Paralelos entre a Teoria de Conjuntos Aproximados e a Teoria de Dempster-Shafer**. Relatório do Departamento de Computação. São Carlos: DC-UFSCar, 1998. Disponível em: <http://www.ginux.ufla.br/~joukim/publicacoes/tds_tca.ps.gz> Acesso em: 12 ago. 2007.

NOGUEIRA, J. H. M. Expert SINTA. In: Simpósio Brasileiro de Engenharia de Software, 10., 1996, São Carlos. **Seção de Ferramentas...** São Carlos, 1996. p. 1-4. Disponível em: <<http://www.lia.ufc.br/~bezerra/exsinta/Download/sbes96.zip>> Acesso em: 13 ago. 2007.

NORSYS SOFTWARE CORP. **Netica Bayesian Network Software from Norsys**. Disponível em: <<http://www.norsys.com/index.html>>. Acesso em: 09 mai. 2007.

OLIVEIRA JR., H. A. **Lógica difusa: aspectos práticos e aplicações**. Rio de Janeiro: Interciência, 1999.

RUMBAUGH, J.; JACOBSON, I. **UML: guia do usuário**. Rio de Janeiro: Campus, 2000.

SALTER, R. B. **Distúrbios e Lesões do Sistema Músculoesquelético**. 3. ed. Rio de Janeiro: MEDSI, 2001.

SANCHEZ, E. **Fuzzy logic and the semantic web**. New York: Elsevier, 2006.

UNIVERSIDADE DO EXTREMO SUL CATARINENSE. Grupo de Pesquisa Inteligência Computacional Aplicada. Disponível em: <<http://www.unesc.net/pesquisa/gp/36/>>. Acesso em: 05 mai. 2007.

WEBER, L.; KLEIN, P. A. T. **Aplicação da lógica Fuzzy em software e hardware**. Canoas, RS: ULBRA - Universidade Luterana do Brasil, 2003.

WILLIAMSON, J. **Bayesian nets and causality: philosophical and computational foundations**. New York: Oxford University Press, 2005.

APÊNDICE A – CLASSE DA INTERFACE

A classe da interface é representada pelo diagrama ilustrado na figura a seguir.

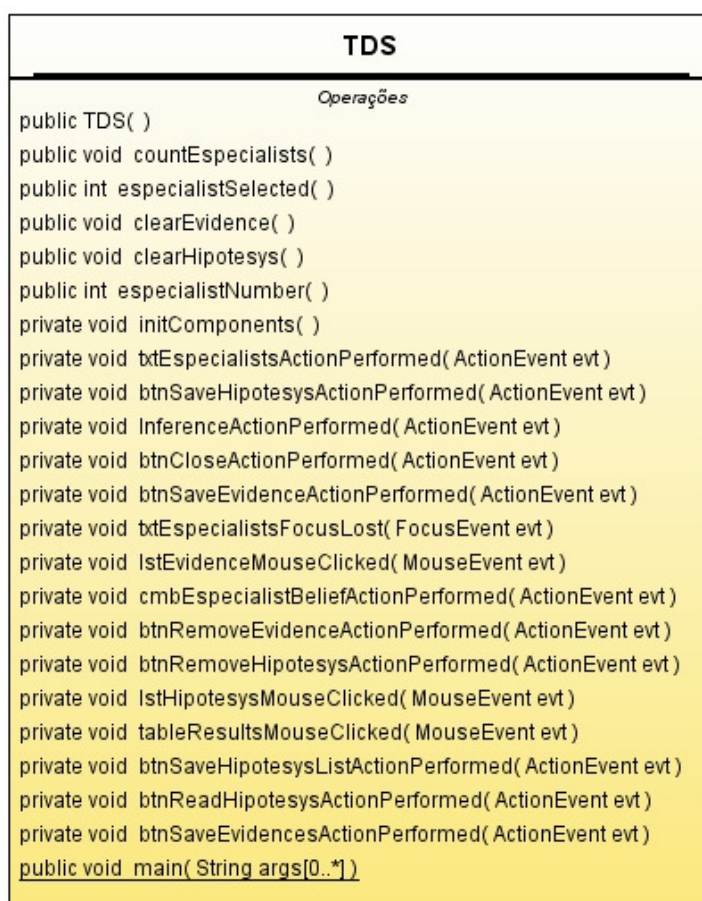


Figura 42. Classe da Interface

Os métodos da classe são descritos a seguir.

- a) *public TDS()*: é utilizado para iniciar todos os componentes gráficos da interface;
- b) *public void countEspecialists()*: é responsável por adicionar o número de especialistas no item de seleção dos mesmos;
- c) *public int especialistSelected()*: retorna o número do especialista selecionado;

- d) *public void clearEvidence()*: limpa os campos referentes a seleção da evidência;
- e) *public void clearHipotesys()*: limpa os campos referentes a seleção da hipótese;
- f) *public int specialistNumber()*: retorna o número de especialistas;
- g) *private void txtEspecialistsActionPerformed(java.awt.event.ActionEvent evt)*: quando ocorrer alguma ação no campo referente à quantidade de especialistas esse método adiciona a quantidade de especialistas no item de seleção dos mesmos;
- h) *private void btnSaveHipotesysActionPerformed(java.awt.event. ActionEvent evt)*: adiciona novas hipóteses à lista das hipóteses;
- i) *private void InferenceActionPerformed(java.awt.event.ActionEvent evt)*: efetua as ações do motor de inferência;
- j) *private void btnCloseActionPerformed(java.awt.event.ActionEvent evt)*: encerra a interface;
- k) *private void btnSaveEvidenceActionPerformed(java.awt.event.ActionEvent evt)*: adiciona novas evidências à lista de evidências;
- l) *private void txtEspecialistsFocusLost(java.awt.event.FocusEvent evt)*: quando o cursor sair do campo referente à quantidade de especialistas esse método adiciona a quantidade de especialistas no item de seleção dos mesmos;
- m) *private void lstEvidenceMouseClicked(java.awt.event.MouseEvent evt)*: ao clicar em alguma evidência na lista das evidências todas as suas informações são mostradas nos campos determinados;

- n) *private void cmbEspecialistBeliefActionPerformed(java.awt.event.ActionEvent evt)*: ao selecionar algum especialista na lista de seleção dos mesmos a crença total dele é apresentada no campo determinado;
- o) *private void btnRemoveEvidenceActionPerformed(java.awt.event.ActionEvent evt)*: remove a evidência selecionada da lista de evidências;
- p) *private void btnRemoveHipotesysActionPerformed(java.awt.event.ActionEvent evt)*: remove a hipótese selecionada da lista de hipóteses;
- q) *private void lstHipotesysMouseClicked(java.awt.event.MouseEvent evt)*: ao clicar em alguma hipótese na lista de hipóteses todas as suas informações são mostradas nos campos determinados;
- r) *private void tableResultsMouseClicked(java.awt.event.MouseEvent evt)*: ao clicar em algum item da tabela de resultados as suas hipóteses são exibidas no campo especificado;
- s) *public static void main(String args[])*: inicia o formulário e o apresenta ao usuário;
- t) *private void btnSaveHipotesysListActionPerformed(java.awt.event.ActionEvent evt)*: salva as informações da lista de hipóteses em um arquivo texto;
- u) *private void btnReadHipotesysActionPerformed(java.awt.event.ActionEvent evt)*: carrega os dados da lista de hipóteses se arquivo de texto correspondente existir;
- v) *private void btnSaveEvidencesActionPerformed(java.awt.event.ActionEvent evt)*: salva as informações da lista de evidências em um arquivo texto.

APÊNDICE B – ARTIGO

O Formalismo da Teoria de Dempster-Shafer na Shell para Modelagem da Incerteza Pegasus

Leonardo Assis da Silva¹

¹Curso de Ciência da Computação, Unidade Acadêmica de Ciências, Engenharias e Tecnologia – Universidade do Extremo Sul Catarinense (UNESC) – Criciúma – SC

leonardossilvadm@gmail.com

Resumo. *Este artigo aborda o estudo de uma teoria para modelagem da incerteza em sistemas especialistas fornecendo considerações sobre a utilização do formalismo matemático de Dempster-Shafer e seus métodos de inferência.*

Abstract. *This article discusses the study of a theory for the uncertainty modeling in expert systems providing considerations on the use of mathematical formalism of Dempster-Shafer and its inference methods.*

Palavras Chave: Inteligência Artificial, Sistemas Especialistas, Motor de Inferência, Teoria da Evidência de Dempster-Shafer.

1. Introdução

As ferramentas da Inteligência Artificial geralmente oferecem uma interface que facilita a construção do motor de inferência, que tem como uma de suas aplicações a modelagem da incerteza. Durante a utilização de um sistema especialista (SE), muitas vezes o conhecimento adquirido é incompleto ou imperfeito, fazendo com que os sistemas atuem sobre dados incertos ou vagos. Por não existir uma teoria genérica que consiga modelar todos os tipos de incerteza, a escolha de um método para a sua representação no motor de inferência é um problema enfrentado durante o desenvolvimento dos Sistemas Especialistas (SE) [Bittencourt 2001].

Algumas ferramentas possuem mais de um método para modelagem da incerteza, como é o caso da *shell* Pegasus que está sendo desenvolvida pelo Grupo de Pesquisa em Inteligência Computacional Aplicada da Universidade do Extremo Sul Catarinense. Essa *shell* idealizada pelo grupo abrange inicialmente quatro módulos, cada um deles utilizando um formalismo matemático diferente para a modelagem da incerteza, são eles: Teoria da Evidência (TDS) de Dempster-Shafer, lógica *fuzzy*, Fatores de Certeza e Raciocínio Probabilístico.

A TDS é um dos modelos mais conhecidos para modelagem da incerteza e visa o tratamento das informações por meio de um formalismo matemático baseado em proposições lidando de forma concreta com o problema da ignorância, que corresponde ao desconhecimento de informações pelo especialista. [Russel e Norvig 2004].

Assim, este artigo abrange o desenvolvimento da inferência de Dempster-Shafer na *shell* Pegasus. Na metodologia foi realizado o levantamento das teorias e trabalhos correlatos, a modelagem matemática da TDS, a modelagem do motor de inferência baseado na TDS para a *shell* de modelagem de incerteza Pegasus, finalizando com a implementação do módulo da TDS.

O artigo apresenta o aplicativo que compreende ao módulo da TDS que foi integrado à *shell* Pegasus, oferecendo as opções de cadastrar hipóteses e evidências e também de apresentar os resultados da inferência ao usuário. Os resultados verificados na ferramenta são satisfatórios demonstrando que os cálculos efetuados encontram-se conforme a bibliografia consultada.

1.1. Modelagem da Incerteza

Ao se utilizar um SE costuma-se observar que o conhecimento pode estar inconsistente gerando conclusões conflitantes, ou ainda incompleto, sem as informações necessárias para se chegar a uma conclusão adequada [Rezende 2005].

A lógica bayesiana é utilizada para a modelagem da incerteza por aleatoriedade, podendo ser utilizado, por exemplo, na previsão do tempo, onde é calculada a probabilidade de um determinado evento climático ocorrer [Costa e Simões 2004].

A lógica *fuzzy*, diferente da teoria bayesiana, é utilizada para a modelagem da incerteza por imprecisão, que apresenta um tipo de informação que não possui seus limites precisamente definidos, como no exemplo citado por Russel e Norvig (2004) que considera que uma pessoa com 1.78m de altura pode ser alta para alguns, mas baixa para outros.

Ao contrário da lógica *fuzzy*, a teoria dos Fatores de Certeza utiliza um único valor numérico para quantificar a incerteza, denominado Fator de Certeza, que indica o grau de certeza de uma regra ou afirmação [Costa e Simões 2004].

Diferente das teorias anteriores, a TDS utiliza graus de crença, com intervalos de probabilidade, para representar o conhecimento incerto. Assim, ao contrário de calcular a probabilidade de uma proposição, a TDS calcula a chance de uma evidência assumir uma determinada hipótese [Russel e Norvig 2004].

1.2. Teoria de Dempster-Shafer

A TDS é uma técnica de modelagem da incerteza em sistemas especialistas, que permite a distinção entre ignorância e incerteza, pois como são conceitos diferentes devem ser tratados de maneira diferente [Russel e Norvig 2004].

Essa teoria baseia-se na atribuição de probabilidades a todos os subconjuntos de um universo de discurso, e não apenas aos membros individuais, como na teoria clássica da probabilidade. O formalismo da TDS suporta ainda o uso de probabilidades subjetivas no raciocínio, que muitas vezes refletem melhor o raciocínio de um especialista humano [Badiru e Cheung 2002].

Diferente das abordagens probabilísticas, que usam apenas um valor para medir uma situação muitas vezes complexa, a TDS é uma alternativa que considera conjuntos de proposições relacionadas a um intervalo de crença e plausibilidade [Luger 2004].

1.3. Inferência pela Teoria de Dempster-Shafer

O Motor de Inferência (MI) é um interpretador da Base de Conhecimento (BC) em um SE, que aplica procedimentos para a solução de problemas. Ao iniciar o sistema ele busca na BC por regras e as compara com os dados fornecidos pelo usuário, sendo esse seu princípio de funcionamento [Fernandes 2003].

A modelagem da incerteza é muito importante no processo de inferência, pois muitas vezes o conhecimento da BC não está completamente correto ou o usuário

não informa os dados suficientes para uma resolução simplificada do problema [Rezende 2005].

Assim, a TDS foi utilizada para o desenvolvimento do motor de inferência no módulo da *shell* Pegasus com o objetivo de oferecer auxílio à tomada de decisão de especialistas.

2. Metodologia

A metodologia utilizada na pesquisa contou com as etapas de levantamento das teorias e trabalhos correlatos, a modelagem matemática da TDS, a modelagem do motor de inferência baseado na TDS para a *shell* de modelagem de incerteza Pegasus, finalizando com a implementação do módulo da TDS.

2.1. Levantamento das Teorias e Trabalhos Correlatos

Os trabalhos encontrados se referem a algumas aplicações e ferramentas encontradas que utilizam a teoria descrita neste artigo. Foram estudados seus objetivos, metodologias, áreas de aplicação, resultados, entre outros.

As aplicações utilizam os conceitos da TDS para realização de alguma tarefa em específico, principalmente para as áreas de geologia, cartografia, sensoriamento remoto e computação gráfica. São todas pesquisas nacionais, publicadas em congressos e periódicos, e uma dissertação de mestrado.

Alguns dos objetivos abordados são: a utilização de técnicas de fusão de sensores para melhorar a informação na área da robótica, classificação de imagens de satélites na área de geologia e cartografia e detecção de falhas em redes de sensores sem fio na área de telecomunicações.

A ferramenta encontrada utiliza uma interface gráfica com o intuito de demonstrar a inferência da TDS de uma forma simples e prática. O *software* possui um material que apresenta as principais características da TDS com o qual o usuário é capaz de utilizar o sistema de uma maneira eficiente.

2.2. Modelagem Matemática

Para o desenvolvimento dessa etapa do projeto foi adaptada uma BC da área da saúde que contém doenças relacionadas a lombalgia, desenvolvida em 2001 [Scussel 2001].

Lombalgia é a dor ou indicação clínica causada por alguma patologia na região lombar do paciente, existindo cerca de 50 doenças que causam essa dor, sendo que a BC apresenta apenas 6, devido a alta prevalência [Scussel 2001].

Esse assunto foi tratado inicialmente por meio do formalismo das redes bayesianas apresentando as seguintes hipóteses diagnósticas (HDs): artrite, espondilite anquilosante, artrite reumatoide, espondilolistese e lombalgia muscular.

O processo de construção da rede bayesiana foi apresentado no trabalho desenvolvido, no curso de Ciência da Computação da UNESC. Na construção da BC foram coletados dados pelo especialista em Ortopedia e Traumatologia e professor do curso de medicina da UNESC, Robson Luiz dos Santos [Scussel 2001].

Por meio da *shell* Netica foi exemplificada a utilização da BC, a qual contém as HDs ilustradas na Figura 1.

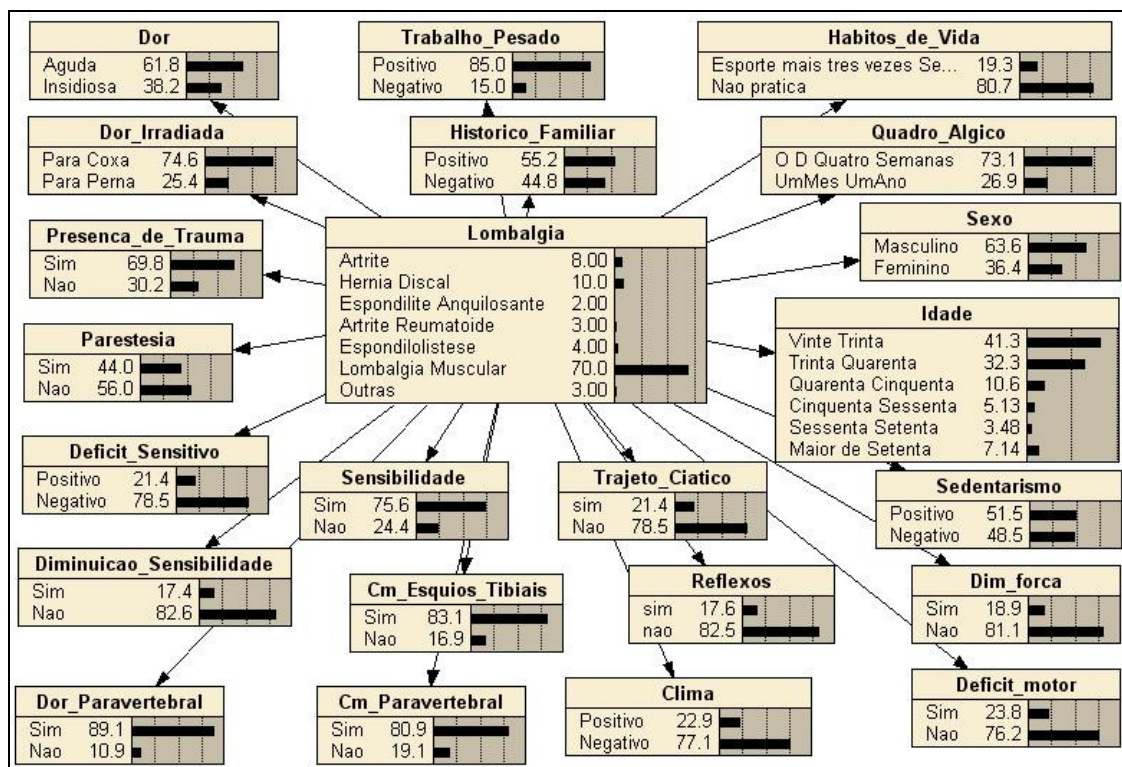


Figura 1. Base de Conhecimento da Lombalgia

A fim de facilitar a simulação de diagnósticos por diferentes especialistas optou-se em utilizar esta rede bayesiana desenvolvida por Scussel (2001) para representar as hipóteses utilizadas no estudo de caso.

Ao utilizar a BC da lombalgia simulou-se sua utilização por alguns especialistas e os valores *a posteriori* das evidências e HDs foram registrados para o cálculo da TDS.

As hipóteses utilizadas foram elaboradas a partir das seleções feitas na rede bayesiana resultando o domínio do problema em $\Theta = (\text{Artrite } \{A\}, \text{Hérnia Discal } \{HD\}, \text{Espondilite Anquilosante } \{EA\}, \text{Artrite Reumatoide } \{AR\}, \text{Espondilolistese } \{E\}, \text{Lombalgia Muscular } \{LM\}, \text{Outras } \{O\})$, onde o domínio do problema representa as hipóteses primitivas em um universo de discurso.

Assim, para determinar as evidências conforme explicado anteriormente, o especialista deve verificar os sinais e sintomas do paciente e efetuar a seleção na rede bayesiana ilustrada na Figura 1 verificando quais as prováveis doenças. Essas probabilidades representam então os valores que são utilizados na modelagem matemática e para entrada na lista das evidências.

Desse modo, será exemplificada a modelagem matemática supondo um caso hipotético de um paciente com dores na região lombar que resolve procurar um especialista.

O médico (1º especialista) ao atender o paciente solicita algumas informações efetuando o registro na rede bayesiana apresentada na Figura 1. Os sinais e sintomas observados pelo especialista foram: trabalho pesado, não pratica esportes, ausência de trauma, histórico familiar positivo, sexo masculino, idade entre 50 e 60 anos, não é sedentário (devido a sua profissão), não possui diminuição de força, não possui diminuição de sensibilidade e não possui déficit motor. Finalizada a anamnese, as hipóteses diagnósticas da BC se encontram como na Figura 2.



Figura 2. HDs verificadas pelo primeiro especialista

Na TDS isso indica uma crença $m_1(\{LM\}) = 0.518$ baseando-se na hipótese de lombalgia muscular verificada na BC. Supondo que o 1º especialista informe apenas essa hipótese ao paciente e esse não questione sobre as outras HDs menos relevantes a única informação que ele possui é a probabilidade de lombalgia muscular.

Assim, como descrito por Badiru e Cheung (2002), a soma de todas as atribuições feitas por um especialista a todos os subconjuntos de Θ deve ser igual a 1, conforme indica a fórmula 1:

$$\sum_{A \in 2^\Theta} m(A) = 1 \quad (1)$$

Dessa maneira, como o paciente não questionou sobre as probabilidades das demais hipóteses diagnósticas, o valor 0.482 deve ser atribuído a $m_1(\Theta)$, indicando a crença nas demais hipóteses diagnósticas na rede bayesiana.

$$m_1(\Theta) = 0.482$$

O paciente resolve procurar um outro especialista a fim de reforçar o diagnóstico e tratamento do 1º. O 2º especialista utiliza o mesmo método de perguntas do 1º e usa a mesma rede bayesiana, e ao finalizar a consulta, verifica os seguintes sinais e sintomas: trabalho pesado, não pratica esportes, ausência de trauma, histórico familiar positivo, sexo masculino, idade entre 50 e 60 anos, não é sedentário, não possui diminuição de força, não possui diminuição de sensibilidade, não possui déficit motor e possui déficit sensitivo. Assim, a hipótese diagnóstica mais significativa é a artrite, com uma probabilidade de 59,4%, indicando uma crença $m_2(\{A\}) = 0.594$ conforme ilustra a Figura 3.




Figura 3. HDs verificadas pelo segundo especialista

Supondo que o 2º especialista informe apenas essa hipótese ao paciente e esse não questione sobre as outras HDs menos relevantes a única informação que ele possui é a probabilidade de artrite.

Assim, como o paciente não questionou sobre as probabilidades das demais hipóteses diagnósticas, a fórmula 1 deve ser aplicada e o valor 0.406 deve ser atribuído a $m_2(\Theta)$, indicando a crença nas demais hipóteses diagnósticas na rede bayesiana.

$$m_2(\Theta) = 0.406$$

Finalizada a segunda consulta, o paciente compara as duas recomendações de tratamento e diagnóstico realizado e observa que apresenta dois diagnósticos e tratamentos distintos.

Assim, pode-se utilizar a regra de Dempster para combinar as evidências dos dois especialistas e determinar o valor da crença combinada.

$$m_n(Z) = \frac{\sum_{X \cap Y = Z} m_{n-2}(X) m_{n-1}(Y)}{1 - \sum_{X \cap Y = \emptyset} m_{n-2}(X) m_{n-1}(Y)} \quad (2)$$

A Tabela 1 apresenta o início do cálculo mostrando apenas a intersecção das hipóteses e a multiplicação dos valores do numerador. A primeira coluna apresenta os valores das crenças nas hipóteses verificadas pelo 1º especialista (m_1), a segunda coluna apresenta os valores das crenças nas hipóteses verificadas pelo 2º especialista (m_2) e a 3ª coluna apresenta os valores das crenças combinadas entre m_1 e m_2 , ou seja, a multiplicação dos valores e a intersecção dos conjuntos de m_1 e m_2 .

O valor de m_3 é considerado inicialmente provisório, pois depende da verificação das evidências que possuem conjuntos de hipóteses nulos.

Tabela 1. Combinação das evidências no caso da lombalgia para obtenção de m_3

| m_1 | m_2 | m_3 (provisório) |
|-----------------------|-----------------------|---------------------------|
| $m_1(\{LM\}) = 0.518$ | $m_2(\{A\}) = 0.594$ | $m_3(\{\}) \cong 0.308$ |
| $m_1(\Theta) = 0.482$ | $m_2(\{A\}) = 0.594$ | $m_3(\{A\}) \cong 0.286$ |
| $m_1(\{LM\}) = 0.518$ | $m_2(\Theta) = 0.406$ | $m_3(\{LM\}) \cong 0.21$ |
| $m_1(\Theta) = 0.482$ | $m_2(\Theta) = 0.406$ | $m_3(\Theta) \cong 0.196$ |

Pode-se perceber que a soma das crenças atribuídas pela função de *bpa* é igual a 1, provando assim a fórmula 1, ou seja:

$$\sum_{A \in 2^\Theta} m(A) = 1$$

$$m_3(\{\}) + m_3(\{A\}) + m_3(\{LM\}) + m_3(\Theta) = 0.308 + 0.286 + 0.21 + 0.196 = 1$$

Continuando o raciocínio, como existe um conjunto de hipóteses vazio ($m_3(\{\})$) a crença deve ser normalizada. Assim o denominador a ser utilizado na aplicação da fórmula 2 é:

$$1 - m_3(\{\}) \cong 1 - 0.308 \cong 0.692$$

O resultado da crença combinada (m_3) dos dois especialistas resulta em:

$$m_3(\{A\}) \cong 0.286 / 0.692 \cong 0.414$$

$$m_3(\{LM\}) \cong 0.21 / 0.692 \cong 0.304$$

$$m_3(\Theta) \cong 0.196 / 0.692 \cong 0.283$$

Os valores de $m_3(\text{conjunto})$ representam a crença em cada conjunto, e com eles é possível calcular a crença total e a plausibilidade, que indica o intervalo que se

pode acreditar nas probabilidades calculadas. Com a utilização das fórmulas a seguir será mostrado como ficam os intervalos.

$$bel(A) = \sum_{B \subseteq A} m(B) \qquad pl(A) = \sum_{B \cap A = \emptyset} m(B)$$

A crença na hipótese do paciente apresentar artrite ($bel(\{A\})$) é calculada por meio da soma de todas as *bpa* dos conjuntos de hipóteses contidos ou iguais a $\{A\}$ e para calcular a plausibilidade na hipótese do paciente apresentar artrite ($pl(\{A\})$) deve-se somar todas as *bpa* dos conjuntos de hipóteses cuja intersecção com $\{A\}$ não resulte em um conjunto vazio. Assim, o intervalo $[bel(\{A\}), pl(\{A\})]$ resulta em:

$$[bel(\{A\}), pl(\{A\})] = [m(\{A\}), m(\{A\}) + m(\Theta)] = [0.414, 0.414 + 0.283]$$

$$[bel(\{A\}), pl(\{A\})] = [0.414, 0.696]$$

Os demais intervalos são calculados da mesma forma. Para:

d) lombalgia muscular $\{LM\}$:

$$[bel(\{LM\}), pl(\{LM\})] = [m(\{LM\}), m(\{LM\}) + m(\Theta)] = [0.304, 0.304 + 0.283]$$

$$[bel(\{LM\}), pl(\{LM\})] = [0.304, 0.586]$$

e) domínio do problema (Θ) :

$$[bel(\Theta), pl(\Theta)] = [m(\Theta) + m(\{A\}) + m(\{LM\}), m(\Theta) + m(\{A\}) + m(\{LM\})]$$

$$[bel(\Theta), pl(\Theta)] = [0.414 + 0.304 + 0.283, 0.414 + 0.304 + 0.283] = [1, 1]$$

A partir desse cálculo pode-se observar que a crença total apresenta a soma de todas as outras *bpa*, o que não ocorre conseqüentemente nos demais intervalos que representam parte do domínio do problema.

Assim, estes resultados representam o limite mínimo e máximo em que o especialista pode confiar para tomar sua decisão, para:

e) artrite: $[bel(\{A\}), pl(\{A\})] = [0.414, 0.696]$;

f) lombalgia muscular: $[bel(\{LM\}), pl(\{LM\})] = [0.304, 0.586]$;

g) domínio do problema: $[bel(\Theta), pl(\Theta)] = [1, 1]$.

Finalizada a definição dos intervalos de crença e plausibilidade, segue-se com o cálculo do peso de conflito para verificar a viabilidade da utilização dos formalismos matemáticos da TDS. Para esse cálculo deve-se efetuar a soma de todos as crenças cujo conjunto de hipóteses é vazio ($m_3\{\}$) da terceira coluna da Tabela 1 para determinar o valor da constante κ :

$$\kappa = \Sigma(m_3\{\}) = 0.308$$

Para concluir o cálculo do peso de conflito deve-se então aplicar a fórmula a seguir:

$$con(m_1, m_2) = \log(1 / 1 - \kappa) \cong \log(1.445) \cong 0.160$$

Pode-se notar que o resultado obtido está dentro dos limites estabelecidos da teoria, que indica valores menores ou iguais a 0.6 [Costa e Simões 2004].

Com a modelagem matemática concluída foi possível efetuar o desenvolvimento do motor de inferência e com ele a implementação do *software*, este que corresponde ao módulo da TDS na *shell* Pegasus e oferece além do motor de inferência, uma interface com o usuário que o auxilia no cadastro das informações na

base de conhecimento e também apresenta de forma sucinta as informações referentes à execução da inferência.

2.3. Módulo da TDS na *shell* Pegasus

O módulo da TDS é responsável por executar quatro passos principais: cadastrar hipóteses, cadastrar evidências, efetuar a inferência e mostrar os resultados. O cadastro das hipóteses é realizado por meio da parte da interface ilustrada na Figura 4. Nela é possível cadastrar ou remover hipóteses, dentre outras opções.

Figura 4. Interface de manutenção da lista de hipóteses

O cadastro das evidências é realizado por meio da parte da interface ilustrada na Figura 5. Nela é possível cadastrar ou remover evidências, assim como salvar as informações cadastradas em um arquivo texto para posterior utilização.

Figura 5. Interface de manutenção da lista de evidências

A combinação de evidências é efetuada por meio da seleção da opção de combinação das evidências conforme ilustra a Figura 6.

Figura 6. Botão da Inferência

Ao selecionar esta opção, os métodos e fórmulas apresentados na modelagem matemática são executados, e o resultado é informado conforme ilustra a Figura 7, que apresenta o painel dos resultados.

| Resultados | | | |
|------------|---------------|--------|----------------|
| Nome | Probabilidade | Crença | Plausibilidade |
| LM | 0,304 | 0,304 | 0,586 |
| A | 0,414 | 0,414 | 0,696 |
| Domínio | 0,283 | 1,000 | 1,000 |

Peso de Conflito:
0,160

Gráficos

Fechar

Hipóteses:

Figura 7. Interface dos resultados da inferência

O desenvolvimento foi realizado em Java por ser uma linguagem portátil muito utilizada no meio acadêmico, com a utilização do ambiente de desenvolvimento NetBeans IDE 6.0.1 por ser uma ferramenta gratuita, e modelado por meio de diagramas UML por representar um padrão de modelagem.

3. Considerações Finais

Durante a utilização de um sistema especialista costuma-se observar que o conhecimento pode estar inconsistente gerando conclusões conflitantes, ou ainda incompleto, sem as informações necessárias para se chegar a uma conclusão adequada. Devido a carência de uma teoria genérica que consiga modelar todos os tipos de incerteza, a escolha de um método para a sua representação no motor de inferência é um problema rotineiro enfrentado durante o desenvolvimento dos sistemas especialistas.

Assim, este artigo demonstrou o processo de inferência por meio dos formalismos matemáticos da teoria de Dempster-Shafer na *shell* Pegasus *Uncertainty Modeling*.

Conforme apresentado, a TDS é uma técnica voltada ao tratamento da incerteza por ignorância e utilizada para o desenvolvimento do motor de inferência no respectivo módulo da *shell* Pegasus.

Ao utilizar esta teoria foram compreendidos seus formalismos e por meio deles, apresentada a modelagem matemática, aplicada ao diagnóstico de lombalgia, que contou com conhecimentos do especialista em Ortopedia e Traumatologia, Robson Luiz dos Santos, que faz parte do corpo docente do curso de Medicina da UNESC.

A partir da modelagem matemática realizou-se a modelagem e implementação do sistema que se deu na linguagem Java por meio do ambiente NetBeans IDE 6.0.1. O aplicativo resultante corresponde ao módulo da TDS que foi integrado à *shell* Pegasus, que oferece as opções de cadastrar hipóteses e evidências e também de apresentar os resultados da inferência ao usuário.

4. Referências

- Badiru, A. B. e Cheung, J. Y. (2002) “Fuzzy engineering expert systems with neural network applications”. New York: J. Wiley.
- Bittencourt, G. (2001) “Inteligência artificial: ferramentas e teorias”. 2.ed. Florianópolis: UFSC.
- Costa, E. e Simões, A. (2004) “Inteligência Artificial: fundamentos e aplicações”. Lisboa: FCA.
- Fernandes, A. M. R. (2003) “Inteligência Artificial: noções gerais”. Florianópolis: Visual Books.

- Luger, G. F. (2004) “Inteligência artificial: estruturas e estratégias para a resolução de problemas complexos”. 4. ed. Porto Alegre: Bookman.
- Rezende, S. O. (2005) “Sistemas inteligentes: fundamentos e aplicações”. Barueri: Manole.
- Russel, S. J. e Norvig, P. (2004) “Inteligência Artificial”. Rio de Janeiro: Elsevier.
- Scussel, T. (2001) “Base de Conhecimento para um Sistema Especialista de Apoio ao Diagnóstico Etiológico da Lombalgia”. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – Criciúma: Universidade do Extremo Sul Catarinense.

ANEXO A – PROJETO DO PIBIC**DECLARAÇÃO**

Declaramos para os devidos fins, que **Pryscila Waleska Targino de Azevedo Simões**, participa como orientadora no projeto de pesquisa intitulado: **“Modelagem de incertezas híbridas na área de inteligência computacional aplicada: desenvolvimento de uma Shell para construção automatizada de sistemas inteligentes”** no Programa de Institucional de Bolsas de Iniciação Científica – PIBIC da Pró-Reitora de Pós-Graduação, Pesquisa e Extensão desta Universidade, no período de 01 de agosto de 2007 a 31 de julho de 2008, com a carga horária semanal de 02 (duas) horas.

Criciúma, SC, 13 de junho de 2008.


Roseli Jenoveva Neto

Pró-Reitora de Pós-Graduação, Pesquisa e Extensão.

ANEXO B – DIAGNÓSTICO DA LOMBALGIA

8. Diagnóstico da Lombalgia

“Logo após o resfriado comum, a dor lombar é a aflição mais comum no homem. Entre 70 e 80 % da população do globo sente dor lombar em algum momento de suas vidas” (BERKER, 1993).

“A grande maioria dos pacientes com dor lombar tem condições subjacentes que podem ser diagnosticadas e tratadas em ambulatório. A maioria dos pacientes não requer hospitalização ou cirurgia. A tarefa consiste em separar os poucos que exigem um tratamento mais agressivo daqueles que vão se recuperar com manejo conservador” (BERKER, 1993).

8.1 Doenças Existentes e Doenças Diagnosticadas

Existem aproximadamente 50 doenças que cursam com dor lombar , destas, foram contempladas seis, devido a sua alta prevalência .

O sistema irá diagnosticar as seis doenças abaixo descritas, bem como os seus sinais e sintomas:

Espondilite Ancilosante: “A espondilite ancilosante (EA) é um distúrbio inflamatório de etiologia desconhecida que acomete principalmente o esqueleto axial, embora também possa atingir articulações periféricas e estruturas extra articulares” (FAUCI,1998).

Artrite (osteoartrite ou osteoartrose): “A osteoartrite, também chamada de artropatia degenerativa, é o tipo mais comum de doença articular. Caracteriza-se pela erosão progressiva da cartilagem articular.

O termo osteoartrite subentende uma doença inflamatória , é considerada uma doença intrínseca da cartilagem na qual alterações bioquímicas e metabólicas resultam na sua degradação” (COTRAN,2000).

“A osteoartrose é uma das doenças mais antigas e mais comuns do mundo. Trata-se de processo basicamente degenerativo (artrose) e não inflamatório.

A osteoartrose é afecção degenerativa eminentemente crônica das articulações móveis, sobretudo do quadril, joelho e vértebras (que suportam mais peso) e que se caracteriza, basicamente, por degeneração progressiva e perda da cartilagem articular coexistindo esclerose óssea subcondral e proeminências ósseas nas bordas articulares (osteófitos)” (BRASILEIRO,2000).

Artrite Reumatóide: A artrite reumatóide (AR) é uma doença multissistêmica crônica de causa desconhecida. A característica típica da AR é uma sinovite inflamatória, persistente, geralmente comprometendo articulações periféricas em uma distribuição simétrica”(FAUCI,2000).

Espondilolistese: “A espondilolistese é geralmente definida como um deslizamento ou deslocamento anterior ou posterior de uma vértebra, com relação a outra. O defeito unilateral ou bilateral da parte interarticular sem deslocamento da vértebra é conhecido como espondilólise. O termo espondilolistese (foi cunhado por Kilian em 1854) derivado do grego “spondylo”, significando vértebra, e “olisthesis”, significando deslizamento”(CAMPBELL, 1996).

Hérnia Discal: “Discos intervertebrais herniados são a causa mais comum de dor em pescoço ou região lombar associada a uma anormalidade estrutural claramente definida. Entre cada dois corpos vertebrais existe um disco intervertebral fibrocartilaginoso. O disco consiste em núcleo pulposo interno liso (anel fibroso). Um núcleo pulposo gelatinoso age como um absorvente de choque entre corpos vertebrais adjacentes. Com o envelhecimento, o núcleo perde o líquido, volume e elasticidade, e a estrutura do disco torna-se mais suscetível a traumas menores repetidos, e caso alarguem, uma porção do núcleo pulposo hérnia. Na herniação de disco a maioria dos pacientes mantém o pescoço rígido e resiste a movimentos passivos” (BENNETT,1996).

Lombalgia por causa muscular: Lombalgia por causa muscular é a dor ou desconforto na região lombar, às vezes causada pelo estresse, geralmente envolve a contração ou espasmo dos músculos ao longo da espinha que servem para sustentar a espinha. Uma dor generalizada ao longo da espinha pode ser devido a estiramento do músculo, trauma nas costas ou estresse

mecânico. Lombalgia devido ao estresse pode ser causada pela fadiga ou contração generalizada, devido a permanência numa mesma posição por um tempo prolongado, como trabalhar sentado por horas. O estresse pode deixar a pessoa mais tensa e criar tensão muscular, que é fator de risco da lombalgia.

8.2 Sinais e Sintomas envolvidos no diagnóstico

As doenças podem ocorrer na forma clássica, onde os sinais e sintomas permitem ao médico o diagnóstico evidente da patologia, pois esses dificilmente contemplam outras doenças. Porém em grande parte dos casos acontece a interposição de sinais e sintomas caracterizando quadros clínicos não clássicos. Dessa forma, a apresentação clássica das doenças, que permitiria um rápido e fácil diagnóstico infelizmente não aparece corriqueiramente, fazendo com que o conjunto de sinais e sintomas levem o médico geralmente a estabelecer hipóteses diagnósticas de várias doenças, com percentuais probabilísticos diferentes. Tornando-se essencial para o médico reunir o maior número possível de informações e analisá-las para que possa chegar da forma mais fidedigna a esse diagnóstico. Os sinais e sintomas que compõem o quadro clínico das doenças que cursam com lombalgia possuem particularidades que à sua análise permitem ao médico chegar com um certo grau de segurança as hipóteses diagnósticas.

Há determinados distúrbios mais comuns em indivíduos mais jovens e outros associados com indivíduos mais idosos, com contribuição relevante relacionada ao sexo. A duração, a forma de início e as características da dor auxiliam na decisão do seguimento e formato da anamnese, sendo direcionada pelo médico no transcorrer da consulta. Além da sintomatologia, fatores como a história ocupacional e social do indivíduo exercem influência na dor lombar. Pacientes jovens, submetidos a esforço muscular exaustivo, sem história de trauma em geral são portadores de lombalgia de causa biomecânica. Pacientes com hérnia discal classicamente apresentam um quadro de dor irradiada para o membro inferior, associada com déficit sensitivo e motor. Indivíduos idosos, com dor lombar sem irradiação, sem história de trauma em geral são portadores de artrose lombar. Pacientes com quadro de dor poliarticular associada com dor lombar e rigidez matinal possuem maior possibilidade de portarem uma doença reumática. O exame físico tem por objetivo demonstrar anomalias estáticas e dinâmicas que possam descartar ou não determinadas doenças, acrescenta dados

essenciais para o diagnóstico sendo condizentes ou não com as queixas referidas pelo paciente durante a anamnese.

Ao final da anamnese e exame físico deve o médico reunir informações necessárias para formular um diagnóstico, conduzindo de forma criteriosa a solicitação de exames adicionais, que confirmem suas hipóteses.