

**UNIVERSIDADE FEDERAL DE SANTA CATARINA**

**CENTRO TECNOLÓGICO**

**DEPARTAMENTO DE INFORMÁTICA E DE ESTATÍSTICA**



**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA  
COMPUTAÇÃO**

***SISTEMAS ESPECIALISTAS PROBABILÍSTICOS***

Prof<sup>a</sup> Silvia Modesto Nassar  
silvia@inf.ufsc.br

Junho de 2012

## SUMÁRIO

1	Introdução.....	2
1.1	Inteligência Artificial e Incerteza.....	2
1.2	Sistemas Especialistas Probabilísticos: redes bayesianas .....	5
2	Probabilidade.....	8
2.1	Espaço de Probabilidade .....	9
2.2	Eventos Compostos .....	10
2.3	Terminologia para os conectivos E e OU.....	10
2.4	Eventos Disjuntos .....	10
2.5	<i>LATTICE</i> .....	11
2.6	Axiomas e Propriedades de Probabilidade .....	11
2.7	Probabilidade Condicional .....	12
2.8	Propriedades da Probabilidade Condicional .....	12
3	Raciocínio Bayesiano. ....	14
3.1	Teorema de Bayes.....	14
3.2	Independência de Eventos.....	15
3.3	Teorema de Bayes com Evidências Múltiplas e Independentes .....	15
3.4	Atualização Bayesiana para uma Nova Evidência .....	16
3.5	Hipóteses Multivaloradas: algoritmo de solução .....	17
3.6	Razões de Probabilidade .....	18
3.7	Probabilidade Condicional e Implicação Lógica.....	21
4	Sistemas Especialistas Probabilísticos.....	22
4.1	Exemplos de Sistemas Desenvolvidos .....	23
4.2	<i>Shells</i> disponíveis .....	32
4.3	Aquisição de Conhecimento .....	39
5	Avaliação de Sistemas Especialistas .....	42
5.1	Avaliação de Desempenho .....	43
a)	Intervalo de Confiança para Percentual .....	44
b)	Validade Interna do Sistema .....	50
5.2	Tamanho da Amostra ( Base de Teste ) .....	55
5.3	Exemplo de Aplicação.....	57
6	Referências .....	63
	<b>ANEXO 1 - Endereços sobre Bayesian Networks .....</b>	<b>64</b>
	<b>ANEXO 2 – Entropia .....</b>	<b>65</b>
	<b>ANEXO 3 – Listas de Exercícios .....</b>	<b>69</b>

# 1 Introdução

Neste capítulo são apresentados conceitos básicos referentes ao desenvolvimento de sistemas especialistas em domínios com a presença de incerteza. Os seguintes itens serão considerados: Inteligência Artificial e Incerteza; Formas de Tratamento de Incerteza; Sistemas Especialistas Probabilísticos (SEP): redes bayesianas.

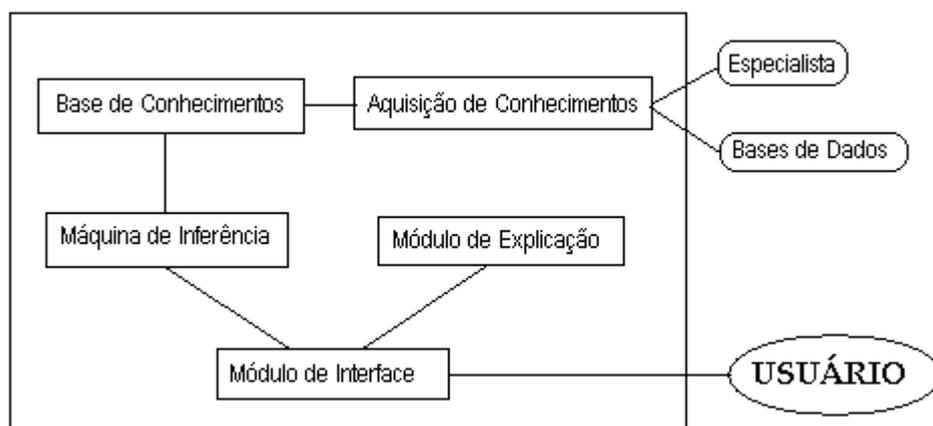
## 1.1 Inteligência Artificial e Incerteza

A Inteligência Artificial surgiu quase que simultaneamente ao computador digital. Nesta época foram implementados programas baseados na noção de busca em um grafo de espaço-estado. A partir da metade da década de 60, procurou-se dar ao computador capacidade de entendimento, através de conhecimentos específicos e outros mais gerais sobre o mundo. A partir da metade dos anos 70 muitas pesquisas vêm sendo desenvolvidas na área de sistemas especialistas, dentre estes estão os baseados na representação explícita do conhecimento de um especialista humano. Atualmente, a IA tem sido aplicada nas mais diversas áreas, por exemplo: na robótica, reconhecimento de padrões em imagens de satélites, reconhecimento de padrões em imagens médicas, sistemas de apoio ao diagnóstico médico, sistemas de ensino-aprendizagem e em diversos sistemas de controle industriais.

Um conceito sucinto para Inteligência Artificial (IA) é a transferência de características do comportamento inteligente para as máquinas. Esta área da informática tem como objetivo desenvolver programas computacionais capazes de emular o raciocínio de um, ou vários especialistas, num domínio específico. Estes programas devem ser capazes de interagir com os usuários, de forma amigável, resolvendo problemas como o próprio especialista resolveria, bem como devem oferecer explicações satisfatórias de seu raciocínio e, ainda, devem ser capazes de continuar aprendendo ao longo de sua vida útil. Assim, os sistemas especialistas devem ter algumas características essenciais nos dias atuais, tais como: capacidade de trabalhar com incertezas; capacidade de oferecer explicações ao usuário; flexibilidade de adaptação de sua base de conhecimentos a outro especialista; e capacidade de continuar aprendendo. Pode-se ilustrar os módulos que compõem um sistema especialista conforme a Figura 1.1.

Observe que a capacidade de aprendizagem continuada de um sistema especialista pode ocorrer se o engenheiro de conhecimento implementar um módulo de aquisição de conhecimentos (Figura 1.1), aonde o sistema poderá se comunicar com o especialista inicial de desenvolvimento ou outro especialista usuário do sistema, ou ainda aprender de base de dados utilizando as técnicas de *Data Mining* ou de *Knowledge Discovery in Database*. Quando uma rede bayesiana está ligada à uma base de dados ela torna-se adaptativa e se atualiza conforme as probabilidades estimadas nos dados armazenados, sendo chamadas de redes bayesianas adaptativas. Uma outra possibilidade seria a capacidade de aprender por meio da alteração de sua topologia, podendo acrescentar ou retirar variáveis da base de conhecimento, sendo chamadas de redes bayesianas dinâmicas.

Figura 1.1 - Arquitetura de um Sistema Especialista



Os dois grandes paradigmas para o desenvolvimento de sistemas especialistas em IA são: o paradigma simbólico e o paradigma sub-simbólico (conexionista). No paradigma conexionista são utilizadas técnicas de redes neurais para representar e solucionar problemas num domínio específico. Este paradigma é aplicável a domínios onde a forma de raciocínio do especialista não pode ser totalmente explicitada. No paradigma simbólico o conhecimento do especialista é disposto numa base de conhecimentos, onde as inferências são representadas através de regras do tipo SE-ENTÃO. Geralmente, o raciocínio do sistema é baseado numa árvore de decisões. Neste caso, o conhecimento do especialista deve ser adquirido e representado de forma mais aprofundada possível, para permitir que o sistema emule o comportamento do especialista.

Em muitos problemas do mundo real, chega-se a uma solução sob a presença de incerteza. A incerteza num domínio de aplicação pode estar presente nos dados de entrada, na solução do problema ou em ambos. Por exemplo, no caso de diagnóstico médico os sinais e sintomas que o médico coleta e trabalha apresentam vários problemas de incerteza, tais como: a inexatidão dos relatos do paciente e a percepção da intensidade de cada sintoma, entre outros. Além disso, o próprio raciocínio clínico não pode ser realizado com certeza, isto é podem existir dois pacientes com dois conjuntos similares de sinais e sintomas e seus diagnósticos serem diferentes. Torna-se então necessário pesquisar formas de representação de incerteza nos *inputs* e no raciocínio de sistemas especialistas aplicados a domínios com a presença de incerteza.

Existem, basicamente, dois métodos de representação de incertezas: o simbólico e o numérico. O método simbólico trata incertezas através de regras de inferência que representam as exceções no raciocínio do especialista e, portanto é viável para trabalhar com uma pequena quantidade de exceções. Muitas vezes as exceções às regras de inferência são explicitadas com o objetivo de aumentar o conhecimento do sistema para resolver problemas. Se as exceções forem muitas, torná-las explícitas pode ser uma tarefa extremamente difícil o que inviabilizaria esta forma de representação. Outro fator a considerar é que as exceções devem ser identificadas e representadas no SE antes de serem realizadas inferências e combinações de *inputs*. Por outro lado, o método numérico propaga a incerteza numericamente através das inferências e combinações de evidências.

Os principais paradigmas numéricos de representação de incerteza são:

- **Fatores de Certeza:** o sistema especialista associa a cada uma de suas informações um determinado grau de certeza. Este método surgiu com o sistema MYCIN (Shortliffe 1976) e foi muito utilizado no desenvolvimento dos primeiros sistemas especialistas.
- **Teoria dos Conjuntos Difusos ( *Fuzzy Set* ):** representa a incerteza por imprecisão, isto é trabalha com conjuntos com limites imprecisos. Muito utilizada para representar termos linguisticamente imprecisos, como ‘homem obeso’, por exemplo. Na lógica clássica, com base na Teoria Clássica dos Conjuntos, um elemento pertence ou não ao conjunto; enquanto, na lógica difusa (*Fuzzy Logic*) um elemento possui um grau de

pertinência ao conjunto, que varia de 0 a 1, este grau é obtido por meio da função de pertinência que representa o conjunto no domínio de aplicação.

- **Teoria da Probabilidade:** representa a incerteza por aleatoriedade, isto é não se pode prever com toda certeza o que acontecerá num novo caso, mesmo diante do conhecimento estocástico de casos anteriores do domínio de aplicação. Utiliza uma estrutura rigorosa de representação de eventos aleatórios, aonde a probabilidade de um evento ocorrer assume valor de 0 a 1. Estas probabilidades são caracterizadas por funções de distribuição de probabilidade. Nestes sistemas é considerada também a probabilidade de que ocorra um evento B (“consequência”) condicionada a ocorrência de outro evento A (“causa”), esta probabilidade é suportada pelo teorema de Bayes.
- **Teoria da Evidência:** a teoria de Dempster-Schafer, como é conhecida, trata a representação de incertezas de forma semelhante à da Teoria de Bayes. No entanto o raciocínio é feito com medidas de crença, que são obtidas por meio de funções de crença. Estas funções tornam-se úteis quando agregadas pela regra de combinação de Dempster de modo a gerar uma única função de crença.

Na UFSC, principalmente a partir da década de 90, vêm sendo realizadas pesquisas onde são desenvolvidos sistemas especialistas utilizando a lógica *fuzzy* para tratar a incerteza, por imprecisão, presente em diversos domínios de aplicação – Sistemas Fuzzy. Desde 1995, aproximadamente, vem sendo explorada a utilização da teoria da probabilidade como paradigma de tratamento de incerteza, por aleatoriedade, no desenvolvimento de sistemas especialistas - Sistemas Especialistas Probabilísticos ou Bayesianos. Finalmente, destaca-se que desde 2001 tem-se proposto uma abordagem híbrida para tratar conjuntamente a aleatoriedade e a imprecisão presentes em alguns domínios de aplicação, são os chamados Sistemas Híbridos Fuzzy-Bayes.

## 1.2 Sistemas Especialistas Probabilísticos: redes bayesianas

Os Sistemas Especialistas Probabilísticos (SEP) têm em sua base de conhecimentos fatos e regras que representam o conhecimento do especialista num domínio de aplicação. Aos fatos e às regras são associados às incertezas presentes no domínio, e são explicitados as

chances de sua ocorrência por meio de valores de probabilidade. O raciocínio realizado pelo sistema deve considerar estas probabilidades para a partir dos dados de entrada (*input*) associar um vetor de probabilidades ao conjunto de hipóteses diagnósticas ou categorias de classificação do sistema (*output*). A hipótese com maior probabilidade de ocorrência pode ser considerada a classificação ou conclusão do sistema, note que a esta conclusão está sempre associado o grau de certeza da resposta do sistema.

As redes bayesianas são esquemas de representação de conhecimentos utilizadas para desenvolver a base de conhecimentos (Figura 1.1) de um sistema especialista probabilístico. Elas têm uma parte estrutural refletindo relações causais entre as variáveis de entrada (*inputs*) e a variável de saída (*output*) do sistema e valores de probabilidade refletindo a força da relação. Geralmente, a rede bayesiana é extraída de um especialista que transfere seus conhecimentos do domínio de aplicação para o engenheiro de conhecimentos do sistema. Porém, pesquisas vêm sendo realizadas buscando construir redes bayesianas utilizando algoritmos capazes de estimar os valores das probabilidades bem como identificar os nodos da rede a partir de bases de dados (*Learning Machine*).

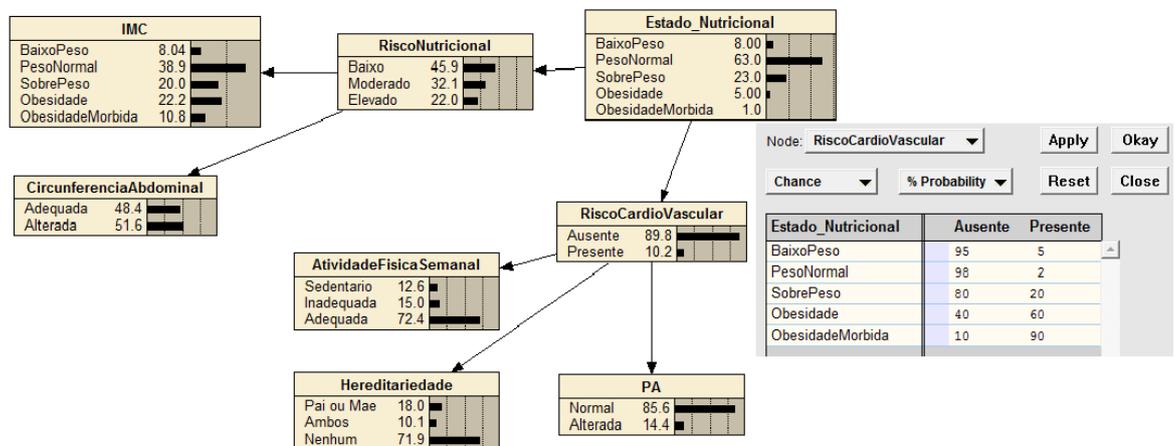
As redes bayesianas trabalham com relações causais quantificadas por valores de probabilidade condicional. Segundo Bender (1996), “*a causalidade é a vantagem de nossa existência e a desvantagem de nossa matemática. Acreditamos em causalidade em nossas interações com a realidade, mas é difícil capturá-la em nossos modelos*”.

Considerando que a causa precede o efeito, é fundamental ter um processo unidirecional para modelar a causalidade. Isto é, se B causa A, então B ocorre antes de A. No contexto da lógica clássica, a implicação não capta uma relação causal por problemas de falta de direcionalidade. Nela temos que  $(\mathbf{B} \rightarrow \mathbf{A})$  é equivalente a  $(\neg \mathbf{B} \rightarrow \neg \mathbf{A})$  assim não permite que a causalidade seja modelada.

Nos sistemas baseados em regras as declarações SE-ENTÃO são interpretadas de forma unidirecional. As redes semânticas também incorporam direcionalidade pelo uso de grafos direcionados. O conceito de probabilidade condicional é sugestivo de causalidade, mas sem uma conexão direta. Dessa forma, nas redes bayesianas são utilizadas estruturas de grafos direcionados no espaço de eventos  $\epsilon$  [Pearl, 1988].

As redes bayesianas (Figura 1.2) são compostas de duas partes complementares: uma parte qualitativa e a outra quantitativa [Gaag, 1996]. A parte qualitativa é um modelo gráfico (grafo acíclico direcionado) onde as variáveis são os nodos e as regras, que são as relações de dependência entre as variáveis, são os arcos direcionados. Assim um arco ligando as variáveis **A** e **B**, na seguinte forma **A**→**B**, indica que a variável **B** é a consequência e a variável **A** é a causa, e estas apresentam uma relação de dependência, resumidas na regra “se **A** então **B**”. Por outro lado, se não houver um arco ligando duas variáveis então se assume que essas variáveis são independentes.

Figura 1.2 – Exemplo de uma rede bayesiana para Diagnóstico de Estado Nutricional



A parte quantitativa de uma rede bayesiana é composta por três classes de probabilidade:

- o conjunto de probabilidades condicionais associadas aos arcos existentes no modelo gráfico da parte qualitativa.
- as probabilidades estimadas a priori das hipóteses diagnósticas ou categorias de classificação (nodo de saída).
- as probabilidades de cada nodo de entrada.

As probabilidades condicionais e as probabilidades do nodo de saída representam o conhecimento do especialista, e as probabilidades de cada nodo de entrada são calculadas utilizando a teoria da probabilidade a partir dos valores já elicitados do domínio.

Um usuário de um SEP especifica observações quando realiza uma consulta ao sistema, isto é, ele instancia o sistema para aquele caso de interesse. Cada observação pode ser considerada como uma informação sobre o valor de uma variável aleatória. E, geralmente, o usuário está interessado em conhecer valores de probabilidade sobre outra variável aleatória (nodo de saída ou nodo das hipóteses diagnósticas ou de classificação). Estes valores de probabilidade são estimados pelo SEP por meio da utilização da Teoria da Probabilidade, mais precisamente pelo teorema de Bayes.

Há dois tipos de cálculo realizados por uma rede bayesiana: a atualização de crenças e a revisão de crença a cada consulta realizada. A atualização de crenças é o cálculo das probabilidades das variáveis aleatórias. Enquanto a revisão de crenças refere-se à obtenção das probabilidades das hipóteses diagnósticas e a identificação da hipótese diagnóstica com maior valor de probabilidade. Esta hipótese diagnóstica mais provável pode ser vista como a explicação mais satisfatória para o conjunto de evidências (*inputs*) em mãos. Numa rede bayesiana pode-se observar a propagação de um dado de entrada em toda a rede, permitindo observar a quantidade de informação daquele dado específico.

Neste momento cabem duas questões iniciais para o desenvolvimento de sistemas especialistas probabilísticos: O que são os valores de probabilidade associados aos fatos e regras do SEP? Como o sistema raciocina com estes conhecimentos? Para responder a estas perguntas são apresentados, a seguir, conceitos de probabilidade.

## **2 Probabilidade**

Se perguntarmos à você qual a probabilidade de ocorrer cara ao lançar uma moeda de um real? É quase certo que sua resposta seria que a probabilidade é igual a 0,50 . Aqui deve-se ressaltar dois aspectos: que você não tinha certeza de que face ocorreria ao lançar a moeda, isto é você estava diante da aleatoriedade do resultado; e que ao expressar o valor 0,50

você estava explicitando uma medida de crença na ocorrência de cara com base em seu suposto conhecimento da situação.

Nos sistemas especialistas probabilísticos os valores de probabilidade refletem a crença do especialista sobre o que ele espera que ocorra em situações similares àquelas que tem experienciado e aprendido ao longo de sua vivência. Isto é, o especialista está tentando extrapolar com base em sua experiência e aprendizado no domínio de aplicação.

Supondo agora a seguinte situação:

Eu lanço a moeda de um real, observo o resultado e não digo a você. Qual a probabilidade de ter ocorrido cara?

Sua resposta continuaria sendo 0,50. Porém, eu que vi o resultado poderia declarar um ou zero. Qual a resposta correta, a sua ou a minha? As duas respostas estão corretas!!! Aqui vale ressaltar que *a probabilidade é baseada em informação*. Eu conheço como a moeda caiu e você somente conhece que a moeda foi lançada. Assim, nossas respostas diferentes refletem nosso estado de conhecimento sobre a situação.

A idéia de que as probabilidades se alteram com a mudança de conhecimento é crucial para o desenvolvimento de sistemas especialistas probabilísticos.

## 2.1 Espaço de Probabilidade

Seja  $\epsilon$  um conjunto finito e  $\mathbf{P}$  uma função de  $\epsilon$  para os números reais não negativos, tal que:

$$\sum \mathbf{P}(\mathbf{e}) = 1 \quad \forall \mathbf{e}: \mathbf{e} \in \epsilon$$

O par  $(\epsilon, \mathbf{P})$  é chamado de espaço de probabilidade. Os elementos de  $\epsilon$  são chamados de eventos simples ou elementares.  $\mathbf{P}$  é chamado de distribuição de probabilidade ou função de probabilidade. Desta definição resulta que a probabilidade de qualquer evento  $\mathbf{e}$ , denotada por  $\mathbf{P}(\mathbf{e})$ , é medida por um número no intervalo  $[0;1]$ .

Intuitivamente,  $\epsilon$  é a coleção de resultados que se pode esperar em um domínio de aplicação. O valor  $P(e)$  é uma estimativa da crença de que o resultado  $e$  ocorra.

## 2.2 Eventos Compostos

Seja um espaço de probabilidade  $(\epsilon, P)$ .

Um subconjunto  $A$  do conjunto  $\epsilon$  é denominado de evento composto.

Para um evento composto  $A$ ,  $A \subseteq \epsilon$  define-se a probabilidade do evento  $A$  da seguinte forma:

$$P(A) = \sum_{e \in A} P(e)$$

Se  $e$  ocorre e  $e \in A$  então diz-se que  $A$  ocorre.

Ao evento composto  $A$  consistindo do conjunto de elementos de  $\epsilon$  que não estão em  $A$  é chamado de negação ou complemento de  $A$  e é denotado por  $\neg A$  ou  $\bar{A}$ .

## 2.3 Terminologia para os conectivos E e OU

Considerando dois eventos  $A$  e  $B$  e adotando a terminologia  $\wedge$  e  $\vee$  para os conectivos **e** e **ou**, respectivamente; então:

$P(A \wedge B)$  significa a probabilidade de que ambos os eventos ocorram; isto é a probabilidade do evento  $A$  ocorrer **e** do evento  $B$  ocorrer.

$P(A \vee B)$  significa a probabilidade de que pelo menos um dos eventos ocorra; isto é a probabilidade do evento  $A$  ocorrer **ou** do evento  $B$  ocorrer.

## 2.4 Eventos Disjuntos

Denotando por  $\cup$  e  $\cap$  a união e a intersecção de conjuntos então:

$$A \cup B = \{ e: e \in A \text{ OU } e \in B \}$$

$$A \cap B = \{ e: e \in A \text{ E } e \in B \}$$

Se  $A \cap B = \emptyset$  então  $A$  e  $B$  são ditos eventos disjuntos ou mutuamente excludentes, e  $P(A \cap B) = 0$ .

## 2.5 LATTICE

Um sistema  $\mathcal{E}^A = (\mathcal{E}, f_1, f_2, \dots, f_n)$  onde o elemento  $\mathcal{E}$  é um conjunto e os outros elementos são operações definidas neste conjunto então  $\mathcal{E}^A$  é denominada uma estrutura algébrica.

Uma estrutura algébrica é uma *lattice* se atende às seguintes propriedades:

a) Idempotência

$$\forall A \in \mathcal{E} \text{ então } A \wedge A = A \text{ e } A \vee A = A$$

b) Comutatividade

$$\forall A, B \in \mathcal{E} \text{ então } A \wedge B = B \wedge A \text{ e } A \vee B = B \vee A$$

c) Associatividade

$$\forall A, B, C \in \mathcal{E} \text{ então } (A \wedge B) \wedge C = A \wedge (B \wedge C) \text{ e } (A \vee B) \vee C = A \vee (B \vee C)$$

d) Lei de Absorção

$$\forall A, B \in \mathcal{E} \text{ então } (A \wedge B) \vee A = A \text{ e } (A \vee B) \wedge A = A$$

Considerando o espaço de probabilidades  $(\mathcal{E}, P)$  pode-se afirmar que se constitui numa estrutura algébrica, que por sua vez é uma *lattice*.

## 2.6 Axiomas e Propriedades de Probabilidade

a)  $0 \leq P(A) \leq 1$

b)  $P(\mathcal{E}) = 1$

c)  $P(A \vee B) = P(A) + P(B)$  se  $A$  e  $B$  forem eventos disjuntos.

d) Se  $A \subseteq B \subseteq \mathcal{E}$  então  $0 \leq P(A) \leq P(B) \leq 1$

e) Se  $A, B \subseteq \mathcal{E}$  então  $P(A \wedge B) + P(A \wedge \bar{B}) = P(A)$  e  $P(A \vee B) = P(A) + P(B) - P(A \wedge B)$

f)  $P(A) + P(\bar{A}) = 1$

g) Se  $A_i \subseteq \mathcal{E}$  para  $1 \leq i \leq n$  e  $A_i \cap A_j = \emptyset$  então para todo  $i \neq j$

$$P(A_1 \vee A_2 \vee \dots \cup A_n) = P(A_1) + P(A_2) + \dots + P(A_n)$$

## 2.7 Probabilidade Condicional

Considerando agora que duas moedas de um real foram lançadas. Adicionalmente, sabe-se que pelo menos uma cara ocorreu. Como construir um novo espaço de probabilidade  $(\mathcal{E}, \mathbf{P}')$  que seja consistente com o espaço de probabilidade  $(\mathcal{E}, \mathbf{P})$  anterior e com a nova informação?

A construção de um novo espaço de probabilidade  $(\mathcal{E}, \mathbf{P}')$  onde o anterior  $(\mathcal{E}, \mathbf{P})$  é alterado devido a uma nova informação é o problema central no desenvolvimento de sistemas especialistas probabilísticos. O conceito de probabilidade condicional permite considerar as novas informações de forma a obter as novas probabilidades.

Sejam  $\mathbf{A}$  e  $\mathbf{B}$  eventos compostos de um espaço de probabilidades  $(\mathcal{E}, \mathbf{P})$ . Suponha que um evento simples  $e$  ocorra. A probabilidade  $\mathbf{P}(\mathbf{B})$  é a probabilidade de que  $e \in \mathbf{B}$  dado nosso conhecimento inicial refletido por  $\mathbf{P}$ . Intuitivamente,  $\mathbf{P}(\mathbf{B}|\mathbf{A})$  é a probabilidade que  $e \in \mathbf{B}$  quando se tem a informação adicional de que  $e \in \mathbf{A}$ .

Seja  $(\mathcal{E}, \mathbf{P})$  um espaço de probabilidade e seja  $\mathbf{A} \subseteq \mathcal{E}$  tal que  $\mathbf{P}(\mathbf{A}) \neq 0$ . Definindo um novo espaço de probabilidade  $(\mathcal{E}, \mathbf{f})$  da seguinte forma:

$$\mathbf{f}(e) = \begin{cases} \mathbf{P}(e) / \mathbf{P}(\mathbf{A}) & \text{se } e \in \mathbf{A} \\ 0 & \text{se } e \notin \mathbf{A} \end{cases}$$

para qualquer  $\mathbf{B} \subseteq \mathcal{E}$  a probabilidade condicional de  $\mathbf{B}$  dado a ocorrência de  $\mathbf{A}$  é igual a  $\mathbf{f}(\mathbf{B})$ . Observe que neste caso  $\mathbf{A}$  é o novo espaço de probabilidade, onde  $\mathbf{B}$  deve ser analisado.

$$\text{Se } \mathbf{A} = \mathcal{E} \text{ então } \mathbf{P}(\mathbf{B}|\mathbf{A}) = \mathbf{P}(\mathbf{B}).$$

## 2.8 Propriedades da Probabilidade Condicional

Seja um espaço de probabilidade  $(\mathcal{E}, \mathbf{P})$ . Se  $\mathbf{C} \subseteq \mathcal{E}$  então  $\mathbf{P}(\mathbf{C}) \neq 0$ . Segue-se que:

1.  $\mathbf{P}(\mathbf{A}|\mathbf{C}) = \mathbf{P}(\mathbf{A} \cap \mathbf{C}) / \mathbf{P}(\mathbf{C})$
2. Se  $\mathbf{A} \subseteq \mathbf{B} \subseteq \mathcal{E}$  então  $0 \leq \mathbf{P}(\mathbf{A}|\mathbf{C}) \leq \mathbf{P}(\mathbf{B}|\mathbf{C}) \leq 1$

3. Se  $A, B \subseteq \varepsilon$  então  $P(A|C) = P(A \cap B | C) + P(A \cap \bar{B} | C)$  e  

$$P(A \cup B | C) = P(A|C) + P(B|C) - P(A \cap B | C)$$
4. Se  $A_i \subseteq \varepsilon$  para  $1 \leq i \leq n$  e  $A_i \cap A_j = \emptyset$  então para todo  $i \neq j$   

$$P(A_1 \cup A_2 \cup \dots \cup A_n | C) = P(A_1 | C) + P(A_2 | C) + \dots + P(A_n | C)$$
5. Se  $A \subseteq \varepsilon$ ,  $B_1 \cup B_2 \cup \dots \cup B_n$  para  $1 \leq i \leq n$  e  $B_i \cap B_j = \emptyset$  para todo  $i \neq j$  então  

$$P(A) = P(A|B_1) \cdot P(B_1) + P(A|B_2) \cdot P(B_2) + \dots + P(A|B_n) \cdot P(B_n)$$

Considere o exemplo a seguir para ilustrar o conceito de probabilidade condicional.

**Exemplo 2.1-** Eu tenho duas crianças, mas você não sabe seus sexos.

- Qual a probabilidade de eu ter duas meninas?
- Um dia no *shopping* você me encontra com uma menina, que é minha filha. Qual a probabilidade de eu ter duas meninas?
- Se a menina com quem você me encontrou é a minha primeira criança, qual a probabilidade de eu ter duas meninas?

Solução:

$$\varepsilon = \{(F_1 \cap F_2); (F_1 \cap M_2); (M_1 \cap F_2), (M_1 \cap M_2)\}$$

onde

$F_i$  significa que a criança  $i$  é do sexo feminino e

$M_i$  que a criança  $i$  é do sexo masculino.

- $P(\text{duas meninas}) = P(F_1 \cap F_2) = 1/4 = 0.25$
- $P(\text{duas meninas} | \text{tenho uma filha}) = P(\text{outra filha} | \text{uma filha}) =$   
 $= P(F_1 \cap F_2) / (P(F_1 \cap F_2) + P(F_1 \cap M_2) + P(M_1 \cap F_2)) = (1/4) / (3/4) = 0.33$
- $P(\text{duas meninas} | \text{minha primeira criança é menina}) = P(F_1 \cap F_2) / P(F_1) =$   
 $= P(F_1 \cap F_2) / (P(F_1 \cap F_2) + P(F_1 \cap M_2)) = (1/4) / (2/4) = 0.50$

Observe que a probabilidade de eu ter duas filhas fica alterada de acordo com a quantidade de informação disponível.

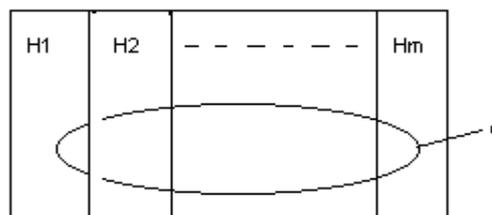
### 3 Raciocínio Bayesiano

Neste capítulo é tratada a representação formal das regras SE-ENTÃO nos sistemas especialistas probabilísticos utilizando o teorema de Bayes. Assim como, são apresentados razões de probabilidades que podem ser utilizadas no refinamento da base de conhecimentos.

#### 3.1 Teorema de Bayes

Seja o espaço de probabilidade  $(\epsilon, \mathbf{P})$  e os eventos compostos  $\mathbf{e}, \mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_K \subseteq \epsilon$  desde que nenhum desses eventos tenha probabilidade nula (Figura 3.1).

Figura 3.1 - Evento  $\mathbf{e}$  e o conjunto de hipóteses  $\mathbf{H}$



Então a probabilidade a probabilidade de ocorrer  $\mathbf{H}_i$  condicionada ao evento  $\mathbf{e}$  fica igual a:

$$P(H_i|e) = \frac{P(e|H_i) \cdot P(H_i)}{P(e)}$$

Considerando agora que:

- ✓ A probabilidade  $P(H_i \wedge e) \neq 0$  para todo  $i$ ;
- ✓ Os eventos  $H_1 \cup H_2 \cup \dots \cup H_k = \epsilon$  e  $H_i \cap H_j = \emptyset$  para todo  $i \neq j$  (isto é, os  $H_i$ 's formam uma partição do espaço  $\epsilon$ )

então:

$$e = (H_1 \cap e) \cup (H_2 \cap e) \cup \dots \cup (H_m \cap e)$$

$$P(e) = P(H_1) \cdot P(e|H_1) + P(H_2) \cdot P(e|H_2) + \dots + P(H_k) \cdot P(e|H_k)$$

resultando na forma geral do teorema de Bayes:

$$P(H_i|e) = \frac{P(e|H_i) \cdot P(H_i)}{\sum_{j=1}^k (P(e|H_j) \cdot P(H_j))}$$

Nas aplicações dos sistemas especialistas probabilísticos os  $H_i$ 's são as hipóteses diagnósticas (nodo de saída). O evento  $e$  pode ser pensado como uma evidência associada a um nodo de entrada. O conhecimento da ocorrência desta evidência leva à mudanças na probabilidade a priori  $P(H_i)$  para a probabilidade condicional  $P(H_i | e)$ , que por sua vez considera a evidência  $e$ .

### 3.2 Independência de Eventos

Seja um espaço de probabilidade  $(\mathcal{E}, \mathbf{P})$ . E, sejam os eventos  $e_1, e_2 \subseteq \mathcal{E}$ . Segue-se que:

- a) Se  $P(e_1 \wedge e_2) = P(e_1) \cdot P(e_2)$  então os eventos  $e_1$  e  $e_2$  são independentes.  
 b) Genericamente, para qualquer subconjunto  $E = \{e_{i1}, e_{i2}, \dots, e_{ik}\}$  de  $\{e_1, e_2, \dots, e_n\}$

se  $P(e_{i1} \wedge e_{i2} \wedge \dots \wedge e_{ik} | H) = P(e_{i1} | H) \cdot P(e_{i2} | H) \dots P(e_{ik} | H)$  então

podemos dizer que os eventos  $e_i$ 's são eventos mutuamente independentes sob a hipótese  $H$ .

A idéia básica subjacente ao conceito probabilístico de independência entre dois eventos é que o conhecimento de certa informação sobre um evento não traz informação adicional sobre o outro. Isto é, se e somente se, ao saber que o evento  $e_1$  ocorreu isto não trazer informação sobre o evento  $e_2$ , e ao saber que o evento  $e_2$  ocorreu isto não trazer informação sobre o evento  $e_1$ , então diz-se que ocorre a independência entre estes eventos.

### 3.3 Teorema de Bayes com Evidências Múltiplas e Independentes

Considerando que temos as  $n$  evidências  $(e_1, e_2, \dots, e_n)$  então a probabilidade da hipótese diagnóstica  $H_i$  é dada por:

$$P(H_i | e_1 \wedge e_2 \wedge \dots \wedge e_n) = \frac{P(e_1 \wedge e_2 \wedge \dots \wedge e_n | H_i) \cdot P(H_i)}{P(e_1 \wedge e_2 \wedge e_3 \dots \wedge e_k \dots \wedge e_n)}$$

Supondo que as evidências são independentes sob a hipótese  $H_i$  então:

$$P(H_i | e_1 \wedge e_2 \wedge \dots \wedge e_n) = \frac{(P(e_1 | H_i) \cdot P(e_2 | H_i) \dots P(e_n | H_i)) \cdot P(H_i)}{P(e_1 \wedge e_2 \wedge e_3 \dots \wedge e_k \dots \wedge e_n)}$$

Resultando em:

$$P(H_i | e_1 \wedge e_2 \wedge \dots \wedge e_n) = \frac{P(H_i) \cdot \prod_{k=1}^n P(e_k | H_i)}{P(e_1 \wedge e_2 \wedge e_3 \dots \wedge e_k \dots \wedge e_n)}$$

### 3.4 Atualização Bayesiana para uma Nova Evidência

Uma característica interessante da regra de atualização de Bayes é seu esquema computacional recursivo e incremental, que propaga cada informação (*input*) dada à rede.

Seja  $H_i$  uma hipótese e  $e^n = e_1, e_2, \dots, e_n$  uma sequência de dados condicionalmente independentes observados no passado e seja  $e$  um novo fato. A probabilidade condicional é igual a:

$$\begin{aligned} P(H_i | e^n \wedge e) &= P(H_i \wedge e^n \wedge e) / P(e^n \wedge e) = \\ &= (P(e^n) \cdot P(H_i | e^n) \cdot P(e | e^n \wedge H_i)) / ((P(e^n) \cdot P(e | e^n))) \end{aligned}$$

resultando em

$$P(H_i | e^n \wedge e) = P(H_i | e^n) \cdot ((P(e | e^n \wedge H_i) / P(e | e^n)))$$

supondo válida a independência condicional sob a hipótese  $H_i$  então

$$P(H_i | e^n \wedge e) = P(H_i | e^n) \cdot ((P(e | H_i) / P(e | e^n)))$$

Observe que:

- $P(H_i | e^n)$  mostra o estado da rede para a informação da ocorrência do evento  $e^n$  no passado;
- $P(e | H_i) / P(e | e^n)$  é a atualização da rede para a nova informação  $e$ .
- Esta atualização é uma razão de crenças, isto é a crença na nova informação  $e$  sob  $H_i$  dividida pela crença na nova informação  $e$  sob os fatos passados  $e^n$ .

Esses resultados mostram que uma vez calculada a probabilidade condicional da hipótese  $H_i$  dado o conjunto  $e^n$  de evidências, isto é o valor  $P(H_i | e^n)$ , os dados passados  $e^n$  podem ser desprezados e assim pode ser obtido o impacto da nova evidência  $e$ . A crença velha  $P(H_i | e^n)$  assume o papel de crença a priori no cálculo do impacto da nova informação  $e$ ; a probabilidade  $P(H_i | e^n)$  sumariza completamente a experiência passada e para sua atualização necessita somente ser multiplicada pela probabilidade  $[P(e | H_i) / P(e | e^n)]$ . Esta probabilidade mede a crença do novo dado  $e$  considerando a hipótese  $H_i$  e os dados passados  $e^n$ .

Vale aqui ressaltar que atualizar recursivamente as medidas de crenças está fortemente relacionado ao conceito de independência condicional sob a hipótese  $H$  visto anteriormente.

### 3.5 Hipóteses Multivaloradas: algoritmo de solução

Nos domínios de aplicação de Sistemas Especialistas Probabilísticos (SEP) é comum a existência de várias hipóteses  $H_i$  concorrentes cada uma com um conjunto distinto de evidências, dizemos então que o sistema tem um conjunto multivalorado de hipóteses. Assim, o SEP deve realizar o diagnóstico, isto é, selecionar a hipótese  $H_j$  (*output*) mais provável (hipótese de classificação) a partir de um conjunto de evidências conhecidas (*input*) e que representam os dados de uma nova consulta ao sistema.

Supondo que temos  $m$  hipóteses e  $n$  evidências vamos, a seguir, obter o vetor de probabilidades condicionais das várias hipóteses concorrentes.

Dado um conjunto de evidências  $e_1, e_2, e_3, \dots, e_k, \dots, e_n$  a crença na  $i$ -ésima hipótese  $H_i$  é dada por

$$P(H_i | e_1 \wedge e_2 \wedge e_3 \dots \wedge e_k \dots \wedge e_n) = \frac{P(e_1, e_2, e_3, \dots, e_k, \dots, e_n | H_i) \cdot P(H_i)}{P(e_1 \wedge e_2 \wedge e_3 \dots \wedge e_k \dots \wedge e_n)}$$

Chamando a probabilidade  $[P(e_1 \wedge e_2 \wedge e_3 \dots \wedge e_k \dots \wedge e_n)]^{-1}$  de **constante de normalização** e denotando por  $\alpha$ . E, supondo a independência condicional das evidências com relação a cada hipótese  $H_i$ , então:

$$P(\mathbf{H}_i | e_1 \wedge e_2 \wedge e_3 \dots \wedge e_k \dots \wedge e_n) = \alpha \cdot P(\mathbf{H}_i) \cdot \prod_{k=1}^n P(e_k | \mathbf{H}_i)$$

Note que:

- a)  $P(\mathbf{H}_i)$  é o vetor de probabilidades a priori das diferentes hipóteses em consideração.
- b) A constante de normalização  $\alpha$  deve ser calculada pela restrição de soma unitária das probabilidades  $P(\mathbf{H}_i | e_1 \wedge e_2 \wedge e_3 \dots \wedge e_k \dots \wedge e_n)$ .

Assumindo ainda, que para evidência  $e_k$  definiremos o vetor  $\lambda^k$  de probabilidades condicionais das  $m$  hipóteses, isto é:

$$\lambda^k = (\lambda_1, \lambda_2, \dots, \lambda_m) \quad \text{onde} \quad \lambda_i = P(e_k | \mathbf{H}_i)$$

Finalmente, podemos reescrever a equação original na seguinte forma:

$$P(\mathbf{H}_i | e_1 \wedge e_2 \wedge e_3 \dots \wedge e_k \dots \wedge e_n) = \alpha \cdot P(\mathbf{H}_i) \cdot \Delta$$

onde 
$$\Delta = \lambda^1 \cdot \lambda^2 \cdot \lambda^3 \cdot \dots \cdot \lambda^n$$

Desta forma torna-se computacionalmente mais fácil obter o vetor de probabilidades condicionais das hipóteses diagnósticas ou de classificação  $\mathbf{H}_i$  dado um conjunto de evidências  $e$ . Por outro lado, com esta expressão, fica também fácil verificar que a regra de atualização Bayesiana apresenta um esquema computacional recursivo e incremental a cada evidência nova informada ao sistema.

### 3.6 Razões de Probabilidade

Razões de probabilidade são chamadas *ODDS* ou *LIKELIHOOD ratio*. No contexto de sistemas especialistas probabilísticos as seguintes razões de probabilidade podem ser utilizadas para entender melhor a distribuição conjunta de probabilidades representada em sua base de conhecimentos:

- a) **ODDS a priori** – é a razão entre as probabilidades de duas hipóteses diagnósticas.

$$O(\mathbf{H}_i) = P(\mathbf{H}_i) / P(\mathbf{H}_j)$$

- b) **ODDS a posteriori** – é a razão entre as probabilidades condicionais de duas hipóteses diagnósticas dado que se conhece a evidência  $e$ .

$$O(H_i | e) = P(H_i | e) / P(H_j | e)$$

c) **LIKELIHOOD ratio** – é a razão entre as probabilidades condicionais de uma evidência  $e$  considerando a ocorrência de uma ou outra hipótese diagnóstica.

$$L(e | H_i) = P(e | H_i) / P(e | H_j)$$

Observe que a *ODDS a priori* mede quão mais provável é a hipótese  $H_i$  em relação à hipótese  $H_j$ . A *ODDS a posteriori* mostra quão mais provável é a hipótese  $H_i$  em relação à hipótese  $H_j$ , porém considerando a ocorrência da evidência  $e$ . Já a *LIKELIHOOD ratio* mede a sensibilidade (confiabilidade) da evidência  $e$  considerando duas hipóteses diagnósticas.

Geralmente estes termos *ODDS* e *LIKELIHOOD ratio* são empregados quando se tem somente duas hipóteses diagnósticas  $H_1$  e  $H_2$ . Estas hipóteses, neste caso, são complementares, isto é,  $H_1 = \bar{H}_2$ .

Pode-se demonstrar que as seguintes expressões são verdadeiras:

$$O(H_i | e) = O(H_i) \cdot L(e | H_i)$$

$$P(H_i | e) = O(H_i | e) / (1 + O(H_i | e)) = 1 / (1 + O(H_i | e))$$

Agora iremos expandir o conceito anterior considerando a ocorrência de uma outra evidência  $e_2$ . Isto é, desejamos saber qual o efeito de uma outra evidência  $e_2$  na probabilidade de uma hipótese  $H_i$ .

$$\begin{aligned} O(H_i | e_1 \wedge e_2) &= P(H_i | e_1 \wedge e_2) / P(H_j | e_1 \wedge e_2) = \\ &= (P(H_i | e_1) / P(H_j | e_1)) \cdot (P(e_2 | H_i \wedge e_1) / P(e_2 | H_j \wedge e_1)) = \\ &= (P(H_i) / P(H_j)) \cdot (P(H_i | e_1) / P(H_j | e_1)) \cdot (P(e_2 | H_i \wedge e_1) / P(e_2 | H_j \wedge e_1)) \end{aligned}$$

supondo que as evidências  $e_1$  e  $e_2$  são condicionalmente independentes então

$$O(H_i | e_1 \wedge e_2) = (P(H_i) / P(H_j)) \cdot (P(H_i | e_1) / P(H_j | e_1)) \cdot (P(e_2 | H_i) / P(e_2 | H_j))$$

Note que a primeira parcela da multiplicação acima é a *ODDS* a priori que reflete a falta de informação de evidências. A segunda parcela reflete a informação sobre a ocorrência da evidência  $e_1$ . A terceira parcela reflete a informação sobre a ocorrência da evidência  $e_2$ . Estas duas últimas parcelas são as *LIKELIHOOD ratios* para as evidências  $e_1$  e  $e_2$ , respectivamente.

Supondo agora a ocorrência de  $k$  hipóteses diagnósticas ou de classificação obtém-se a probabilidade condicional da hipótese  $H_i$  dado as evidências  $e_1$  e  $e_2$  :

$$P(H_i|e_1 \wedge e_2) = \left\{ \sum_{j=1}^K \left[ \frac{P(H_i)}{P(H_j)} \cdot \left( \frac{P(H_i | e_1)}{P(H_j | e_1)} \right) \cdot \left( \frac{P(e_2 | H_i)}{P(e_2 | H_j)} \right) \right] \right\}^{-1}$$

resultando que

$$P(H_i|e_1 \wedge e_2) = [ O(H_j | e_1) \cdot L(e_2 | H_j \wedge e_1) ]^{-1}$$

Geralmente, adota-se que a *LIKELIHOOD ratio* é independente dos dados passados e considera somente a nova evidência  $e$ . Por exemplo, é razoável supor que um paciente desenvolverá um certo sintoma  $e$  considerando que tem a doença  $H_i$  independentemente de que sintomas  $e^n$  teve no passado.

A natureza incremental do processo de atualização para a nova evidência  $e$  pode ser explorado utilizando a razão *ODDS* :

$$O(H_i | e^n \wedge e) = O(H_i | e^n) \cdot L(e|H_i)$$

$$\log O(H_i | e^n \wedge e) = \log O(H_i | e^n) + \log L(e|H_i)$$

assim o logaritmo da *LIKELIHOOD ratio* da evidência  $e$  pode ser visto como um peso da própria evidência  $e$ . Caso a evidência  $e$  suporte a hipótese  $H_i$  então terá um peso positivo, se for oposta a  $H_i$  então terá um peso negativo.

### 3.7 Probabilidade Condicional e Implicação Lógica

Na Teoria da Probabilidade vimos que  $P(A \vee B)$ ,  $P(A \wedge B)$ ,  $P(\neg B)$  eram adequadas aos conectivos lógicos OU, E e NÃO, respectivamente. Será que o conceito de probabilidade condicional  $P(A|B)$  é adequado à implicação lógica ( $\mathbf{B \rightarrow A}$ ), isto é “se B então A”?

Sabe-se que  $(\mathbf{B \rightarrow A}) = (\mathbf{A \vee \neg B})$  então:

$$\begin{aligned} P(\mathbf{B \rightarrow A}) &= P(\mathbf{A \vee \neg B}) = P(\neg B) + P(A \wedge B) = P(\neg B) + P(B \wedge A) = \\ &= P(\neg B) + P(B) \cdot P(A|B) \end{aligned}$$

Como os valores de probabilidade são não negativos então

$$P(\mathbf{B \rightarrow A}) > P(A|B)$$

Dessa forma concluímos que a probabilidade condicional não é adequada à implicação lógica.

A probabilidade condicional utiliza a ocorrência de evidência(s) para chegar à uma conclusão sobre uma hipótese diagnóstica ou de classificação, assim pode ser considerada uma forma de raciocínio.

## 4 Sistemas Especialistas Probabilísticos

Os sistemas especialistas são desenvolvidos para resolver uma grande variedade de problemas, sendo que o conhecimento necessário para solucionar estes problemas, geralmente, não é precisamente definido. Podemos constatar que muitos problemas na vida real são repletos de incerteza. Especialistas humanos nestes domínios são capazes de formar julgamentos e tomar decisões baseados em informação incerta, incompleta e, algumas vezes, até mesma contraditória. Para que um sistema especialista seja confiável, o mesmo deve lidar com este tipo de informação com a mesma facilidade que o especialista humano. O desenvolvimento de formalismos para tratar incerteza e, os algoritmos, para manipular informação com incerteza tornaram-se um tópico maior de pesquisa em IA chamado Raciocínio com Incerteza.

A partir da metade da década de 80, a pesquisa sobre raciocínio probabilístico em sistemas especialistas resultou na introdução de Redes de Crença Bayesianas. Estas redes têm sua fundamentação na teoria da probabilidade e são caracterizadas por um poderoso formalismo que representa o conhecimento no domínio e as incertezas por aleatoriedade associadas a este domínio. Mais especificamente, o formalismo proporciona uma representação concisa de uma distribuição conjunta de probabilidades considerando um grupo de variáveis estocásticas. Associados a este formalismo estão os algoritmos para eficientemente calcular as probabilidades associadas a eventos no domínio de aplicação e para processar as evidências (*input*) relevantes da base de conhecimentos; estes algoritmos constituem as partes básicas para o raciocínio com o conhecimento assim representado. Desde sua introdução, a estrutura de redes bayesianas vem rapidamente ganhando popularidade e agora está começando a mostrar o seu valor em domínios complexos. Aplicações práticas estão sendo desenvolvidas, por exemplo, para diagnóstico e prognóstico médico e para recuperação probabilística de informação (*data mining*).

Como a Teoria da Probabilidade é uma teoria matematicamente bem fundamentada, possuindo uma longa tradição de pesquisa e experiência, não é surpreendente que esta teoria conquiste lugar proeminente na pesquisa de raciocínio com incerteza em sistemas especialistas. Porém, aplicar esta teoria no contexto de um sistema especialista não é tão fácil quanto possa parecer à primeira vista. A aplicação direta dos conceitos básicos da

teoria da probabilidade leva a problemas de complexidade computacional, isto é, a representação explícita de uma distribuição conjunta de probabilidade requer espaço exponencialmente proporcional ao número de variáveis consideradas na rede bayesiana.

#### 4.1 Exemplos de Sistemas Desenvolvidos

Com o objetivo de mostrar algumas aplicações desenvolvidas utilizando a abordagem bayesiana a seguir são comentados alguns exemplos apresentados no quadro 4.1.

✓ **Uma Abordagem Híbrida *Fuzzy*-Bayesiana para Modelagem de Incertezas.**

Nesta pesquisa investigou-se a modelagem conjunta de dois tipos de incerteza: a aleatória e a difusa em sistemas especialistas. Dentre as diferentes abordagens encontram-se as Redes Bayesianas que são utilizadas para tratar a incerteza por aleatoriedade (probabilidade) e os Sistemas Especialistas *Fuzzy* os quais tratam a incerteza por imprecisão (possibilidade). No entanto, em alguns domínios do mundo real, co-existem esses dois tipos de incerteza: a imprecisão e a aleatoriedade. Assim propõe-se uma abordagem híbrida *fuzzy*-bayesiana, para modelar incertezas aleatórias e imprecisas em sistemas especialistas, baseando-se na união da Teoria dos Conjuntos *Fuzzy* e da Teoria da Probabilidade. O hibridismo *fuzzy*-bayes permite trabalhar com a incerteza por imprecisão nas entradas de uma rede bayesiana, formada por nodos dicotômicos ou não dicotômicos. As variáveis com características de imprecisão são fuzzificadas, e propagadas utilizando o teorema de Bayes modificado, gerando uma redistribuição do vetor de probabilidades da saída da rede híbrida. Esta redistribuição ocorre devido ao reconhecimento da incerteza presente nos dados de entrada, encontra-se fundamentada matematicamente e foi avaliada considerando o problema de distúrbio nutricional [Tibiriçá, 2005].

Quadro 4.1 - Exemplos de Sistemas Especialistas Probabilísticos

Nome	Local	Ano	Autor
Procedimentos para Prover Confiabilidade ao Uso de Inteligência Artificial em Ensaios de Desempenho de Compressores Herméticos de Refrigeração	Depto de Engenharia Mecânica da UFSC	2011	Cesar Alberto Penz
Abordagem Bayesiana para Redes sem Fio Cognitivas	Depto de Informática e de Estatística da UFSC	2010	Rafael Mendes
Uma Abordagem Híbrida <i>Fuzzy</i> -Bayesiana para Modelagem de Incertezas	Depto de Informática e de Estatística da UFSC	2005	Carlos Augusto Tibiriçá
ABS-Bayes: Sistema Especialista Probabilístico para Apoio ao Diagnóstico de Absenteísmo	Depto de Informática e de Estatística da UFSC	2003	Nelso Antônio Losi
Modelagem Multiagente Escalonável para Integração de Sistemas Especialistas - CLIDENP	Depto de Informática e de Estatística da UFSC	2003	Michel Barnad Geszychter
Agente Bayesiano de Apoio à Vigilância de Infecção Hospitalar - SAVIH	Depto de Informática e de Estatística da UFSC	2002	Marcos Venicius
Sistema especialista probabilístico para apoio ao diagnóstico de potencial econômico - SEPE	Depto de Informática e de Estatística da UFSC	2002	Hamilton Pasini
Sistema de Avaliação da Evasão Escolar: E-Bayes	Depto de Informática e de Estatística da UFSC	2002	Eugênio Rovaris Neto
Sistema Especialista de Apoio à Nutrição Enteral Pediátrica - SANEP	Depto de Informática e de Estatística da UFSC	2001	Lisiane de Albuquerque
Sistema de Avaliação do Crescimento Infantil - SACI	Depto de Informática e de Estatística da UFSC	2001	Priscyla W. T.A. Simões
Modelo Híbrido Difuso Probabilístico	Depto de Informática e de Estatística da UFSC	2001	Juliano Brignolli
Sistema Especialista Probabilístico: base de conhecimento dinâmica -SEDIN	Depto de Informática e de Estatística da UFSC	2000	Carlos Stein
<i>Baseline</i> Bayesiana para Gerência de Redes de Computadores	Depto de Informática e de Estatística da UFSC	2000	Cleverson Veronez
Sistema de Apoio ao Diagnóstico Diferencial de Cefaléia	Depto de Informática da PUC, Curitiba, Paraná	2000	Renata V. A. Toledo
SISPAN	Depto de Informática e de Estatística da UFSC	1998	Cristiane Koehler
<i>Lógica Autônoma de Controle - Lockheed Martin</i>	<i>Lockheed Martin Marine Systems and Artificial Intelligence Center - Sunnyvale, Califórnia</i>	1998	----
<i>Microsoft Pregnancy and Child Care</i>	<i>Microsoft e Knowledge Industries (KI)</i>	1998	----
DIAVAL	Depto de Informática e Automática - U.N.E.D. - Madrid - Espanha	1994	Fernandez J. Díez
<i>General Electric Aircraft Engines Services</i>	<i>Knowledge Industries (KI) , ENTER Software, California</i>	1989	----
DXplain	Laboratório de Ciência da Computação (Hospital Geral de Massachusetts)	1987	----

- ✓ **Procedimentos para Prover Confiabilidade ao Uso de Inteligência Artificial em Ensaios de Desempenho de Compressores Herméticos de Refrigeração.** Nesta tese de doutorado foi investigado o uso de técnicas de IA para auxiliar a previsão de resultados de ensaios em compressores contribuindo para a diminuição do tempo de avaliação. Foram utilizadas Redes Neurais e Redes *Fuzzy*-Bayesianas. O uso de diferentes técnicas de IA provê confiabilidade aos resultados, conseqüentemente levando à maior aceitação pelas comunidades técnico-científica e industrial [Penz, 2011].
- ✓ **Abordagem Bayesiana para Redes sem Fio Cognitivas.** Nesta pesquisa foi investigada o uso de Redes Bayesianas e Teoria da Decisão para a autoconfiguração e reconfiguração dos equipamentos de rede sem fio. Foram propostas duas Redes Bayesianas, a primeira dedicada ao sensoriamento do espectro e a outra dedicada à caracterização e decisão no espectro com o objetivo de, respectivamente, aumentar a acurácia na detecção de usuários primários e gerenciar a conectividade da rede entre usuários primários, secundários proprietários dos equipamentos e secundários não proprietários. Desta forma, também busca fornecer bases tecnológicas para o compartilhamento altruísta da conectividade à internet, visando sua aplicação com fins sociais [Mendes, 2010].
- ✓ **Uma Abordagem Híbrida *Fuzzy*-Bayesiana para Modelagem de Incertezas.** Esta pesquisa aprofundou a investigação da Lógica *Fuzzy* quando aplicada a nodos de uma Rede Bayesiana que apresentam transição gradual entre suas classes [Tibiricá, 2005].
- ✓ **ABS-Bayes: Sistema Especialista Probabilístico para Apoio ao Diagnóstico de Absenteísmo.** Este sistema busca oferecer apoio a área de recursos humanos de uma empresa detectando os principais problemas de absenteísmo por doenças e suas principais características. Gera dinamicamente uma base de conhecimentos por estar ligado ao banco de dados de exames periódicos dos funcionários e ao banco de dados de atestados médicos apresentados por funcionários que faltam o trabalho. O usuário pode configurar as hipóteses diagnósticas ou deixar que o próprio sistema se encarregue de configurar com as doenças mais prevalentes na empresa [Losi, 2003].

- ✓ **Modelagem Multiagente escalonável para Integração de Sistemas Especialistas.** Foi desenvolvido um protótipo de um sistema multiagente – CLIDENP – Clínica Virtual para Diagnóstico e Educação em Nutrição Pediátrica, que integrou os sistemas especialistas probabilísticos que apóiam o diagnóstico de desnutrição infantil: SISPAN, SACI e SANEP. O sistema CLIDENP foi desenvolvido numa estrutura cliente-servidor. A integração desses sistemas na forma de um sistema multiagente teve como objetivo principal a manutenção da escalabilidade, assim podendo ampliar globalmente a base de conhecimentos pela inserção de novos agentes especialistas [Geszychter, 2003].
- ✓ **Sistema especialista probabilístico para apoio ao diagnóstico de potencial econômico - SEPE .** Este sistema foi desenvolvido para apoiar o planejamento mercadológico a partir do conhecimento do potencial econômico dos municípios de Santa Catarina. Na sua elaboração trabalha-se com dados incertos sobre o mercado, ou seja, tomam-se decisões sem ter as informações necessárias. Para que o diagnóstico seja realizado de uma forma mais eficiente, é necessário que os técnicos visualizem os dados relacionados ao potencial de uma forma gráfica e que sejam investigadas relações entre variáveis endógenas e exógenas aos Correios, por meio de evidências observadas. O sistema SEPE explora o raciocínio probabilístico em sistemas especialistas, com uma base de conhecimentos atualizável. Ainda, emprega técnicas de mineração de dados no processo de aquisição e atualização de conhecimento de uma base de dados. Foi desenvolvido para a plataforma Windows, no ambiente Visual Basic 5, utilizando as DLL's da *shell* Netica [Pasini, 2002].
- ✓ **Agente Bayesiano de Apoio à Vigilância de Infecção Hospitalar - SAVIH.** Este sistema utiliza uma rede bayesiana para apoiar o gestor de um hospital a avaliar o risco de um paciente à infecção hospitalar. Mostra o cenário de infecção nas diversas unidades de internação permitindo fazer a previsão de risco a partir das características epidemiológicas e de doença do paciente. Recupera casos armazenados que forem similares ao paciente ingressante na unidade. Foi desenvolvido utilizando a *shell* Netica [Venicius, 2002].
- ✓ **Sistema de Avaliação da Evasão escolar: E-Bayes.** Este sistema utiliza uma rede bayesiana para apoiar o gestor de uma universidade a avaliar a evasão escolar de um

curso universitário. Mostra o cenário da evasão discente permitindo fazer a previsão da permanência de um aluno no curso a partir de suas características sócio-demográficas. Busca na base de dados quais os alunos do curso que são similares às características do aluno em questão. Explora a aplicação de sistemas especialistas em sistemas de informação. Foi desenvolvido utilizando a *shell* Netica [Rovaris, 2002].

- ✓ **Sistema Especialista de Apoio à Nutrição Enteral Pediátrica - SANEP.** Este sistema identifica a dieta adequada a ser administrada a uma criança desnutrida e calcula toda a fórmula nutricional a partir dos diferentes tipos de leites disponíveis na farmácia de um serviço de atendimento pediátricos. Por questões de segurança, mantém numa base de dados todas as informações de entrada e de saída de um caso consultado [Albuquerque, 2001].
  
- ✓ **Sistema de Avaliação de Crescimento Infantil - SACI.** Esta pesquisa volta-se ao desenvolvimento de um sistema especialista probabilístico para o diagnóstico de alguns distúrbios associados à falência do crescimento em crianças com até 2 anos. O sistema possui uma rede bayesiana composta de um nodo para representar as hipóteses diagnósticas (Deficiência de Ferro, Má Absorção e Etiologia a Esclarecer), e outros três nodos para representar as evidências necessárias para chegar às hipóteses diagnósticas (Diarréia, Taxa de Ferritina e D-Xilosemia). O sistema ainda oferece o acompanhamento do crescimento da criança graficamente, pois para que o diagnóstico seja realizado de uma forma mais eficiente, é necessário que os médicos visualizem os dados relacionados a evolução do crescimento de uma forma gráfica e que sejam investigadas suspeitas de perda de peso e altura da criança, por meio de evidências observadas [SIMÕES, 2001].
  
- ✓ **Modelo Híbrido Difuso Probabilístico.** Nesta pesquisa foi explorada a modelagem de duas formas de incerteza: por aleatoriedade e por imprecisão, utilizando-se a teoria da probabilidade e a teoria dos conjuntos difusos (*fuzzy sets*). Foi desenvolvida uma abordagem para redes bayesianas considerando apenas variáveis dicotômicas. Aplicou-se esta abordagem ao problema de diagnosticar danos à saúde considerando a presença de antibióticos no leite, primeiramente foi implementada uma

rede bayesiana e, após, foi realizado um ajuste nas probabilidades do diagnóstico utilizando graus de pertinência relativos à presença de antibióticos [Brignolli, 2001].

- ✓ **Sistema Especialista Probabilístico: base de conhecimento dinâmica.** Nesta pesquisa foi tomada a base de conhecimentos do sistema SISPAN [Koehler, 1998] e foi desenvolvido um sistema que permite que um usuário possa: incluir/excluir nodos e alterar valores de probabilidade da rede bayesiana. Dessa forma, pode ser avaliada a acurácia de um sistema especialista probabilístico e pode ser utilizado como um ambiente de ensino por simulação [Stein, 2000].
  
- ✓ **Baseline Bayesiana para Gerência de Redes de Computadores.** Este sistema é um módulo inteligente que utiliza informações de uma MIB (*management information base*) para avaliar dinamicamente o tráfego em certo trecho de uma rede de computadores. Oferece como saída as probabilidades das hipóteses diagnósticas do tráfego na rede estar: normal, leve, moderado e intenso a partir dos dados iniciais de hora, dia fornecidos pelo administrador e as informações buscadas na MIB. Foi desenvolvido utilizando a *shell Netica* [Veronez, 2000].
  
- ✓ **Sistema de Apoio ao Diagnóstico Diferencial de Cefaléia.** É um sistema especialista médico que oferece apoio a médicos generalistas, plantonistas ou residentes no diagnóstico diferencial de cefaléias (dores de cabeça). Este sistema utiliza o enfoque de rede bayesiana. A base de conhecimentos foi construída considerando os Critérios de Classificação da Sociedade Internacional de Cefaléias (IHS), levando em conta os sinais e sintomas dos pacientes e nos valores estimados de probabilidades fornecidos pelos especialistas que participaram do projeto. Foi desenvolvido utilizando a *shell Netica*. A avaliação deste sistema foi realizada comparando as respostas fornecidas pelos especialistas e as respostas fornecidas pelo sistema, a partir de um conjunto de fichas médicas de pacientes com cefaléia selecionados aleatoriamente pelos especialistas do projeto. Os resultados experimentais indicam que o sistema foi capaz de fornecer os mesmos diagnósticos que os especialistas do projeto em 95% dos casos. Por outro lado, os mesmos casos clínicos foram avaliados por médicos generalistas e verificou-se que estes obtiveram um percentual de acerto de 53%. Portanto, o sistema desenvolvido apresenta um

desempenho muito bom ao realizar diagnóstico diferencial de cefaléias [TOLEDO, 2000].

- ✓ **SISPAN - Sistema Especialista Probabilístico de Apoio a Avaliação Nutricional.** Este sistema realiza a avaliação nutricional de crianças com até dois anos de idade. Considera como *inputs* os dados relativos a: peso, altura, idade, cabelo, pele, unha, hipotrofia e edema. Classifica o estado nutricional da criança em: sem desnutrição ou com desnutrição, podendo ser leve, moderada ou severa quanto à intensidade, e marasmo, kwashikor ou marasmo-kwashikor quanto ao tipo. Foi desenvolvido utilizando a *shell* Netica, com o módulo de interface com o usuário desenvolvido em C++ [Koehler, 1998].
  
- ✓ **DIAVAL.** É um sistema especialista destinado a ajudar médicos no diagnóstico de doenças cardíacas a partir, principalmente, de dados ecocardiográficos. Este software faz a introdução dos dados, apresentação dos resultados do diagnóstico e explicações sobre o raciocínio, destacando as características que diferenciam o DIAVAL de outros sistemas especialistas e de outras redes bayesianas. Este software é o resultado da tese de doutorado do Prof. Fernandez J. Díez e tem 2 objetivos principais: primeiro, contribuir para o estudo de redes bayesianas e, segundo, aplicar redes bayesianas na construção de um sistema especialista para diagnóstico de ecocardiografia, chamado DIAVAL. Este sistema consiste em calcular a probabilidade *a posteriori*, selecionar a mais provável e a doença mais relevante, gerando um relatório impresso. Outras informações podem ser obtidas no endereço: <http://www.dia.uned.es/~fjdiez/papers/diaval.html>
  
- ✓ **Dxplain.** É um sistema de apoio a decisão que utiliza um conjunto de dados clínicos (sinais, sintomas, dados laboratoriais) para produzir uma lista de diagnósticos associados às manifestações clínicas. Este software possui uma grande base de dados sobre 5000 manifestações clínicas associadas com mais de 2000 diferentes doenças. O Laboratório de Ciência da Computação (do Hospital Geral de Massachusetts) vem desenvolvendo *DXplain* há dez anos; o sistema tem sido utilizado por milhares de médicos e estudantes de medicina. O banco de dados e o sistema estão sendo continuamente aperfeiçoados e atualizados. *DXplain* vem sendo utilizado em vários

hospitais e escolas de medicina para educação clínica e como um auxílio educacional na solução de problemas clínicos. *DXplain* tem as características de livro texto eletrônico e um manual de referência médico. Como um livro texto médico, *DXplain* pode oferecer uma descrição de mais de 2000 doenças diferentes, com ênfase nos sinais e sintomas que ocorrem em cada doença, a etiologia, a patologia e o diagnóstico. *DXplain* também oferece mais de 10 referências para cada doença, dando ênfase para revisões clínicas onde estas estão disponíveis. Outras informações podem ser obtidas no endereço: <http://www.medlib.iupui.edu/dxplain.html>.

- ✓ **General Electric Aircraft Engines Services.** O diagnóstico de falhas em turbinas de aviões em grandes empresas aéreas implica em grandes custos, pois os dados retirados da análise possuem muito ruído e não podem atuar para um defeito específico. As solicitações mecânicas para efetuar os testes e inspeções, assim como a excessiva verificação do motor podem duplicar os custos de manutenção. Para um 757 típico, este custo pode chegar a 500.000 dólares. Contratadas pela *General Electric*, a *Knowledge Industries (KI)* e a *ENTER Software*, de Menlo Park, CA, uma empresa líder em análise de desempenho em tempo-real de turbinas a gás para geradoras de energia elétrica, desenvolveram modelos de redes bayesianas que guiam um mecânico de motores através de uma seqüência otimizada de testes e passos de inspeção. O sistema de recomendação de testes utiliza os resultados de um modelo de desempenho termodinâmico do motor da aeronave, que processa os dados vindos de sensores montados sobre o motor no estande de teste. Mais informações podem ser conseguidas na *home-page* da KI, cujo endereço é: <http://www.kic.com>.
  
- ✓ **Lógica Autônoma de Controle.** A *Lockheed Martin Marine Systems*, em Sunnyvale, Califórnia, em conjunto com o *Artificial Intelligence Center* em Palo Alto, vem desenvolvendo um sistema de controle para o UUV (*Unmanned Underwater Vehicle*). Este veículo submarino poderá permanecer semanas submerso, sem necessidade de intervenção humana. O objetivo da pesquisa é desenvolver um software que seja capaz de controlar eventos planejados e eventos imprevistos, de modo a diminuir o risco de perda do veículo e maximizar a probabilidade de sucesso da missão. O sistema possui maior capacidade de manusear a grande gama de anomalias e alarmes falsos que ocorrem em missões de longa duração, tornando-o bastante superior

aos sistemas atuais. Quando completamente desenvolvido, este sistema permitirá ao UUV monitorar o progresso de sua missão, analisar o estado de seu equipamento, detectar e analisar eventos que causam impacto nos objetivos da missão, tomar decisões e efetuar ações para compensar os eventos, além de modificar o plano da missão quando o atual estiver completamente fora de alcance. Mais informações podem ser obtidas no *site* da *Hugin*: **[www.hugin.dk](http://www.hugin.dk)** .

- ✓ *Microsoft Pregnancy and Child Care*. A *Microsoft* e a *Knowledge Industries* (KI) uniram-se para criar um serviço *on-line* de informação sobre saúde, com capacidade de multimídia, que emprega raciocínio bayesiano. O produto é chamado de *Microsoft Pregnancy and Child Care*, e está disponível no endereço da *Microsoft Network*. Redes bayesianas são o componente central da opção *Find by Symptom* (Busca por Sintoma). Sintomas que ocorrem frequentemente são conectados a módulos especialistas que guiam os pais da criança através de uma série de questões. O sistema repetidamente determina qual a melhor pergunta a se fazer aos pais, mostrando as apresentações em multimídia que correspondem às exatas condições de saúde da criança. Os pais podem escolher entre artigos ilustrados para obter informação detalhada sobre os sintomas e a doença da criança. Os artigos também contém *links* para outras fontes de informação relacionadas, incluindo outros *Web sites*. O *Microsoft Pregnancy and Child Care* foi criado pela Divisão de Consumo da *Microsoft*. A KI desenvolveu e testou as bases de conhecimentos em redes bayesianas, trabalhando com os especialistas Dr. Richard Behrman, Professor de Pediatria na *Stanford University* e na *University of California, San Francisco*, e Dr. David Kerns, Chefe de Pediatria no *Santa Clara Valley Medical Center*. Para maiores informações, consulte **[www.kic.com](http://www.kic.com)**

## 4.2 Shells disponíveis

Neste item são mostradas algumas ferramentas para o desenvolvimento de sistemas especialistas probabilísticos (Quadro 4.2). E, a seguir estão relacionadas as principais vantagens e desvantagens de cada ferramenta.

Quadro 4.2 - Exemplos de *shells* para o desenvolvimento de sistemas especialistas probabilísticos

Nome	Local	Data
<b>NETICA</b>	<i>Norsys Software Corp.</i> - Vancouver, BC, Canadá	1990
<b>BNG</b>	Depto de Engenharia Elétrica e Ciência da Computação - Universidade de Wisconsin-Milwaukee	1995
<b>DxPress</b>	Rockwell Palo Alto Laboratory - Universidade de Stanford	1994
<b>Graphical-Belief</b>	Depto de Estatística - Universidade de Washington	1995
<b>Hugin</b>	Hugin Expert A/S Universidade de Aalborg - Dinamarca	1995
<b>Microsoft Belief Networks</b>	Microsoft	
<b>IDEAL</b>	Rockwell Palo Alto Laboratory	1990
<b>SPIRIT</b>	Universidade de Hagen (FernUniversität Hagen)	1990
<b>Strategist</b>	<i>Prevision Incorporated</i> - Davis - Canadá	1994
<b>BOL</b>	Knowledge Based Engineering (KBE) - África do Sul	1993

- ✓ **NETICA**: este software utiliza redes bayesianas para realizar vários tipos de inferência usando algoritmos modernos e rápidos. Dado um novo caso, que o usuário tem conhecimento limitado, Netica encontrará os valores ou probabilidades apropriadas para todas as variáveis desconhecidas. O caso pode ser, convenientemente, salvo em um arquivo e depois incluído dentro da rede (ou em uma rede diferente) para incrementar a consulta, ou para trazer uma nova informação sobre o caso. Netica pode usar diagramas de influência para encontrar as decisões ótimas, que maximizam os valores esperados das variáveis especificadas. Variáveis que não são de interesse por muito tempo podem ser removidas sem uma mudança geral entre os relacionamentos entre as variáveis remanescentes.

### Vantagens:

- gera uma apresentação gráfica de qualidade, que pode ser incorporada dentro de outros documentos,
- pode encontrar decisões ótimas para problemas de decisão sequencial,
- soluciona diagramas de influência,
- pode aprender relações probabilísticas através de dados,
- permite atualização fácil da rede de crença e dos diagramas de influência, incluindo: excluir, colar e duplicar nodos da rede de crença e dos diagramas de influência,
- mantém diagramas complexo ordenados,
- permite comentários,
- permite desfazer e refazer comando ilimitadamente,
- permite a entrada de relações probabilísticas através de equações, com uma extensa biblioteca de funções probabilísticas e funções matemáticas,
- tem facilidade para realizar a discretização de variáveis contínuas.

Netica está disponível a partir da versão Windows 95 , Windows NT 4.0 e Macintosh; e a versão para UNIX. Mais informações sobre este software podem ser encontradas no endereço: <http://www.norsys.com>

- ✓ **BNG:** é um sistema para construção de base de conhecimentos com redes bayesianas. Uma classe de redes bayesianas é especificada com uma base de conhecimento de regras. Regras podem conter variáveis temporais e não-temporais quantificadas universalmente, bem como restrições do contexto. Restrições do contexto são informações determinísticas utilizadas para indexar relações probabilísticas. Dada uma base de conhecimento, um conjunto de informações sobre o contexto, algumas evidências e uma consulta; BNG constrói uma rede bayesiana estruturalmente mínima para calcular a probabilidade *a posteriori* da consulta. BNG oferece duas vantagens sobre o uso das redes bayesianas tradicionais: representacional e computacional. A incorporação das variáveis quantificadas na base de conhecimento permite a representação da informação não permitidas em redes bayesianas tradicionais. Pois somente uma pequena parte de um grande modelo probabilístico pode ser relevante para o cálculo de uma particular probabilidade posterior, usando BNG pode resultar em economias computacionais significantes. Estas economias podem ser

particularmente grandes com redes bayesianas temporais. A linguagem de representação da base de conhecimento tem uma semântica declarativa e o algoritmos de construção da rede tem se mostrados seguros e completos. BNG está escrito em CommonLisp e possui interface para a ferramenta IDEAL que será apresentada mais adiante. Mais informações no endereço: <http://www.mcw.edu/midas/bng.html>

- ✓ **Graphical-Belief.** É um programa que oferece um ambiente interativo para explorar modelos gráficos baseados em funções de crenças. Uma função gráfica de crença é um modelo de rede que utiliza funções de crença para descrever os relacionamentos entre as variáveis. Este software é dividido em dois módulos principais, a saber: Análise do Modelo e Construção do Modelo. Uma das principais razões para a construção de um modelo estatístico é para fazer prognósticos. *Graphical-Belief* é uma ferramenta para explorar os aspectos preditivos dos modelos. *Graphical-Belief* é baseado na tecnologia de modelos gráficos (também conhecidos como diagramas de influência, redes de crença ou redes bayesianas) que já têm sido muito utilizadas na análise de decisão, inteligência artificial e estatística. Este software oferece várias ferramentas para modelar tarefas, tais como:

### **Organização**

O modelo somente especifica a interação direta entre as variáveis no modelo; *Graphical-Belief* calcula e mostra todas as dependências envolvidas entre variáveis distantes.

### **Engenharia do Conhecimento**

Uma grande quantidade de conhecimento fica armazenada dentro de um modelo gráfico tradicional. *Graphical-Belief* oferece ferramentas para manter este conhecimento. O modelo pode ser desenhado através de uma biblioteca anteriormente construída e de estruturas de conhecimento genérico. Uma outra vantagem em se utilizar o *Graphical-Belief* é que ele utiliza um esquema orientado a objetos para armazenar o conhecimento; uma alteração de uma simples regra do protótipo ou de uma variável é prontamente propagada para todo o modelo.

### **Flexibilidade**

Utilizando *Graphical-Belief*, o usuário poderá selecionar a forma de representação dos relacionamentos entre as variáveis: **probabilidade** (para relacionamentos com incerteza), **lógica** (para relacionamentos com certeza) e **funções de crença** (para

relacionamentos com imprecisão). *Graphical-Belief* completa esta flexibilidade com uma máquina de inferência que pode ser expandida para incluir outras representações para os relacionamentos.

### **Visualização Dinâmica**

Com o *Graphical-Belief* o usuário manipula diretamente o modelo, explorando as implicações entre os relacionamentos.

*Graphical-Belief* tem vários parâmetros flexíveis no sistema, que permitem ao usuário estudar facilmente a sensibilidade de um simples parâmetro, e o seu impacto no modelo. Mais informações sobre este software poderão ser obtidas no endereço: **<http://bayes.stat.washington.edu/almond/gb/graphical-belief.html>**

- ✓ ***Microsoft Belief Network Tools***. Este software permite a criação e avaliação de redes de crença bayesianas. É composto pelo executável MSBN32 que utiliza uma versão proposta pelo *Bayes Net Interchange Format*, isto é, uma representação de um arquivo texto de redes de crença. A aplicação está escrita em Visual Basic 4.0 (32-bit) e possui uma dll (dynamic-link library) para Windows, MSBN32.DLL. Este módulo é o componente ativo do conjunto, e suporta as seguintes operações: a) procura e armazena redes de crença em texto para criação e modificação da rede através da adição de nodos e arcos da avaliação das probabilidades discretas das redes de crença utilizando um método chamado “*exact clique-tree propagation methods decision-theoretic troubleshooting*”; b) diagramas assimétricos de influência. É uma aplicação padrão com interface multi-documentos (MDI) para Windows. Ele tem uma barra de ferramentas e um *help* sensível ao contexto. Esta ferramenta roda em Windows 95 e Windows NT(3.51 ou superior). Está disponível livre de encargos para usuários não-comerciais em organizações de pesquisa e instituições educacionais. Para ter uma cópia do aplicativo, o usuário deverá mandar uma solicitação para:

**<http://www.research.microsoft.com/research/dtg/msbn/>**

- ✓ ***STRATEGIST***. É uma ferramenta para construir e analisar modelos graficamente. Com *Strategist*, o usuário poderá analisar graficamente a sua situação de decisão. Os modelos incluem diagramas de influência para mostrar a estrutura dos relacionamentos

entre as variáveis. *Strategist* é baseado na probabilidade Bayesiana e na teoria de decisão estatística. As principais características do *Strategist* são:

- trabalha com Redes Bayesianas;
- trabalha com diagramas de influência hierárquico;
- possibilita uma rica linguagem para representar o relacionamento entre as variáveis (contingências, relacionamentos *noisy-or* e *noisy-and*, divisões);
- trabalha com variáveis contínuas;
- realiza testes com os modelos utilizando situações do mundo real;
- possui análise de sensibilidade.

Mais informações poderão ser obtidas no endereço:

**<http://www.prevision.com/strategist.html>**

- ✓ **DXPRESS**. É uma ferramenta para aquisição de conhecimento para desenvolvimento rápido de modelos probabilísticos para diagnósticos. Foi escrito em C++, utiliza várias técnicas para acelerar a aquisição do conhecimento, para reduzir o tempo necessário para desenvolver um sistema especialista. Por exemplo, foi desenvolvido um protótipo de sistema de diagnóstico para uma turbina à jato usando energia elétrica e pneumática no DC-10. Este sistema diagnostica 60 diferentes falhas utilizando aproximadamente 50 testes ou observações diferentes. O processo de desenvolvimento total (incluindo os testes) requer somente 8 horas de tempo do especialista e outras 40 horas de tempo do engenheiro de conhecimento.

**Vantagens:**

- avaliação rápida das distribuições de probabilidades utilizando funções de independência causal.
- localiza o progresso durante as diferentes fases da aquisição do conhecimento.
- permite ao usuário dar entrada em notas e definições pertinentes para o processo de aquisição do conhecimento.

Mais informações sobre este software podem ser encontradas no endereço:

**<http://www.kic.com>**

- ✓ **IDEAL** (*Influence Diagram Evaluation and Analysis in Lisp*). É uma base de testes para trabalhar com diagramas de influência e redes bayesianas. Contem diversos

algoritmos de inferência para redes de crença Bayesianas e algoritmos de avaliação para diagramas de influência. Permite criar e editar diagramas de influência e redes de crença bayesianas [SRINIVAS 90]. Foi escrito em Common Lisp. Ao escrever o IDEAL, a ênfase foi na clareza do código e oferecer uma programação de alto nível. Desta forma, o IDEAL é adequado para implementações experimentais que necessitem tecnologia de redes de crença bayesianas. Em aplicações mais avançadas, IDEAL pode ser usado como uma biblioteca de sub-rotinas que oferecem inferência em redes de crença bayesianas e avaliação de diagramas de influência. O código está documentado detalhadamente em um manual. IDEAL vem com uma interface gráfica opcional que depende da versão do Common Lisp que o usuário utiliza. Uma versão para pesquisa do IDEAL pode ser obtida através de *download* na forma de um arquivo .TAR para Unix. O manual vem na forma de um arquivo *Postscript*. Mais informações sobre este software poderão ser obtidas no endereço: <http://rpal.rockwell.com/ideal.html>

- ✓ **SPIRIT.** É uma *shell* para sistemas especialistas criada na Universidade de Hagen (FernUniversität Hagen), na Alemanha. Possui interface gráfica de desenvolvimento. Permite a criação de variáveis de diversos tipos, tais como: booleana, ordinal, cardinal e nominal. A parte qualitativa da rede de crença bayesiana é implementada a partir da inserção de regras de produção. Em seguida, valores de probabilidades são associados a estas regras e às variáveis, caracterizando a parte quantitativa da rede de crença bayesiana. Após a caracterização da rede, faz-se necessário inicializá-la, preparando-a para a compilação, ou seja, aprendizagem das regras. Feita a compilação podemos efetuar inferência sobre a base, inserindo as evidências de um caso específico, chegando a um diagnóstico com um determinado valor de probabilidade.

**Vantagens:**

- facilidade de acesso ao seu criador por meio do intercâmbio da UFSC com a *FernUniversität Hagen*,
- permite maior interação entre usuário e criador, por não ser um software comercial,
- trabalha em várias plataformas, inclusive *Windows*.

Versões de demonstração estão disponíveis em um endereço específico, mantido pela Universidade de Hagen: <http://www.xspirit.de>

- ✓ **HUGIN:** é uma *shell* de origem dinamarquesa para construção de redes de crença. Foi desenvolvida por Frank Jensen e Lars Bo Nielsen. O HUGIN é uma ferramenta capaz de construir modelos considerando a incerteza inerente ao domínio de aplicação. Os modelos suportados são redes de crença bayesianas e diagramas de influência. O HUGIN permite o usuário definir nodos discretos e alguns nodos contínuos em seus modelos.

### **Conceitos Básicos**

Inicialmente, para se utilizar o HUGIN, é necessário que o usuário compreenda os conceitos de redes de crença bayesianos e diagramas de influência. A mais completa descrição matemática de redes de crença Bayesianos e diagramas de influência pode ser encontrada no livro "*Introduction to Bayesian Networks*" de Finn Verner Jensen. A seção de tutoriais do HUGIN Runtime contém informações para ajudar o usuário a construir sua primeira aplicação.

### **A origem do HUGIN**

Durante o projeto ESPRIT sobre diagnóstico de doenças neuromuscular, a rede de crença bayesiana MUNIN foi construída. Um grupo de pesquisa da Universidade de Aalborg trabalhou no desenvolvimento eficiente dos métodos de cálculo para o problema do diagnóstico. Naquela época, pesquisadores americanos obtiveram alguns resultados, mas ainda restava um problema que impedia a utilização de redes de crença bayesianas na construção de sistemas especialistas. O problema foi chamado de *rumour problem*: “Posso ouvir a mesma estória através de diversos canais; mas a estória ainda pode se originar da mesma fonte. Sem saber se meus canais são, ou não, independentes, não posso combinar as declarações corretamente”.

### **Implementação**

HUGIN apresenta a parte qualitativa da rede de forma clara, incluindo a direção dos grafos e a parte quantitativa é apresentada em forma de tabelas.

A primeira fase na implementação de uma base de conhecimentos no HUGIN é a construção da parte qualitativa. Com estas informações é possível definir todas as variáveis e seus respectivos atributos. A parte quantitativa consiste em preencher as tabelas que são apresentadas quando cada variável é selecionada. O tamanho da tabela varia conforme o número de *links* que o nodo observado possui com nodos pais e outros nodos. Nodos pais são os nodos onde chegam grafos de dependências. Finalizando este processo, está terminada a etapa de edição da rede de crença Bayesiana.

A etapa seguinte é a compilação e o programa passa para o modo de execução.

### **Características**

O usuário tem a oportunidade de utilizar o HUGIN através HUGIN Runtime - um ambiente gráfico de fácil acesso. O usuário pode também utilizar o HUGIN API (*Application Program Interface*), que é uma biblioteca de funções para C (ou C++).

O HUGIN pode ser utilizado para construção de modelos como componentes de uma aplicação, principalmente, na área de apoio à decisão e sistemas especialistas. A aplicação pode se comunicar com os modelos construídos através de DDE ou pelo uso da HUGIN API (*Application Program Interface*). Mais informações podem ser encontradas no endereço: <http://www.hugin.dk> .

✓ **BOL** (Bayes On-Line). Este sistema foi desenvolvido pela empresa africana *Knowledge Based Engineering* (KBE), em 1993, com o objetivo de oferecer soluções e serviços através do uso de produtos inteligentes baseados em computador. BOL é uma ferramenta que ajuda a determinar as causas do problema e prognostica eventos futuros em muitas aplicações, principalmente industriais. Ele utiliza um rede para modelar uma aproximação baseada na regra de Bayes da teoria da probabilidade. BOL é valioso para diagnósticos, prognósticos, análise de decisão, análise de risco, análise probabilística de segurança e monitoramento de alarmes. É aplicável a problemas que requerem respostas em tempo real, conectividade, ou ferramentas sofisticadas para decisões estratégicas. Trabalha, preferencialmente, com complexas distribuições de probabilidades, elaboração de árvores de decisão. Para maiores informações sobre este software, podem ser feitas consultas ao *site*:

<http://www.kbe.co.za/products/bol.htm>

Outros softwares para manipulação de redes de crença estão relacionados no endereço:

<http://bayes.stat.washington.edu/almond/belief.html>

### **4.3 Aquisição de Conhecimento**

A aquisição de conhecimento é a fase mais complexa da montagem da base de conhecimentos, por tratar-se da interação entre o engenheiro de conhecimentos e o especialista. Devemos levar em conta a dificuldade inicial do especialista em deixar clara a sua forma de raciocínio. Algumas vezes pode ser muito difícil a transcrição do

conhecimento do especialista para um grupo de regras *SE...ENTÃO*. Neste ponto, o raciocínio probabilístico demonstra uma vantagem, que é a de representar exceções. Não é viável determinar regras para todas as exceções em um domínio proposto. Podemos, então, fixar uma probabilidade de que nosso raciocínio esteja correto, deixando uma margem para as exceções, que geralmente são raras, correspondendo a uma percentagem pequena.

A base de conhecimento de um sistema especialista probabilístico é chamada de Rede Bayesiana, nela o conhecimento é representado esquematicamente na forma de um grafo acíclico direcionado. Os nodos representam dois tipos de variáveis: as variáveis de entrada (sinais ou evidências) e a variável de saída (conjunto de hipóteses diagnósticas). A força da ligação entre as variáveis é expressa no valor das probabilidades condicionais, que representam uma relação causal para a regra "Se A então B". A arquitetura da rede bayesiana é chamada de parte qualitativa da base de conhecimento. E os valores das probabilidades constituem a parte quantitativa da base de conhecimento. Com estas idéias em mente, parte-se para as entrevistas com o especialista.

Para desenvolver a parte qualitativa e a quantitativa da rede bayesiana devemos realizar uma análise preliminar do domínio de aplicação com o objetivo de: explicitar qual o conhecimento necessário, conhecer o raciocínio do especialista e os critérios diagnósticos a serem seguidos pelo sistema. Identificando assim as variáveis ou os nodos da rede bayesiana. Após, buscamos os valores de probabilidade condicional associados aos arcos que ligam o vetor de hipóteses diagnósticas **H** às variáveis de entrada **E**. Lembre-se que os arcos entre nodos indicam a relação *SE-ENTÃO* associada ao sentido da seta, isto é, **H**→**E** indica a relação "Se **H** então **E**".

Recomendamos, ainda, que seja feito inicialmente um pequeno protótipo que permitirá ao especialista visualizar e entender como será representado seu conhecimento no sistema. Após esta fase de prototipação, inicia-se a fase de refinamento até que o sistema aproxime-se do nível de desempenho de um especialista. As sessões de aquisição de conhecimentos devem ser freqüentes e não devem ser muito longas, não excedendo um tempo de aproximadamente duas horas de duração. Este processo é interativo, caro e lento, portanto vale a pena pesquisar maneiras mais automatizadas para construir as bases de conhecimentos, utilizando técnicas de *Data Mining*.

Na realidade, a representação de conhecimentos é a formalização do conhecimento de um sistema. Pode ser imaginada como um conjunto de convenções para se descreverem objetos, fatos e situações. Um mesmo objeto pode ter diversas representações, mas a habilidade de um sistema resolver problemas para os quais foi projetado é altamente influenciada pela escolha da representação.

## 5 Avaliação de Sistemas Especialistas

As pesquisas em IA tem como objeto os programas computacionais que realizam tarefas em determinados ambientes, isto é, certas condições de *software* e *hardware*. Cada programa que é desenvolvido pode ser considerado como uma parte de um laboratório, onde perguntas são respondidas. Em um programa computacional pode-se relacionar sua estrutura e seu comportamento. O estudo de sistemas inteligentes pode ser visto em um cenário com seis componentes: agente (o próprio sistema), tarefa, ambiente, protocolo de experimentação, coleta de dados e análise. O comportamento é o que se observa e se mede quando um agente realiza uma tarefa em um ambiente [Cohen, 1995].

A caracterização do comportamento de um sistema inteligente pode ser feita através de repetição, isto é quando é submetido ao programa um conjunto de problemas a resolver e assim se pode verificar, estatisticamente, se o programa tem o comportamento esperado. O conjunto de problemas submetidos ao programa é chamado de base de teste e, por si só, constitui numa amostra do domínio de aplicação. O pesquisador em IA deve explicitar o comportamento que espera do programa podendo utilizar hipóteses de pesquisa ou mesmo especificando valores aceitáveis de medidas de desempenho, tais como taxas de erro de generalização.

A avaliação de sistemas especialistas ocorre em duas fases distintas: a validação da base de conhecimentos e a avaliação de desempenho do sistema.

Na validação da base de conhecimentos a Estatística oferece procedimentos que permitem analisar a sensibilidade dos parâmetros da base de conhecimentos e a própria estrutura dessa base. A análise de sensibilidade dos parâmetros pode ser entendida como a verificação do impacto de alterações (ruídos) provocados nos parâmetros estimados. Quanto à análise da estrutura da base de conhecimentos, pode-se ter como questão fundamental se os conceitos relevantes do domínio de aplicação estão bem representados.

No caso do paradigma subsimbólico (conexionista) podem ser utilizados procedimentos estatísticos multivariados tais como: componentes principais, análise fatorial, análise discriminante e análise de variância multivariada MANOVA. A utilização destes

procedimentos depende de qual aspecto o engenheiro de conhecimentos deseja avaliar. Por exemplo, num sistema conexionista o engenheiro de conhecimentos poderia estar interessado em avaliar se existe um ou mais grupos de neurônios artificiais que refletem conceitos subjacentes do domínio de aplicação, neste caso poderiam ser aplicados os procedimentos: componentes principais e análise fatorial às estimativas dos pesos das ligações sinápticas. Outro exemplo, ele poderia desejar verificar se a estrutura adotada é representativa do conhecimento do domínio de aplicação, aqui poderia ser empregada a análise discriminante, este procedimento permitiria verificar o valor preditivo das evidências (*input*) em relação às hipóteses diagnósticas (*output*).

Ambas, a análise de sensibilidade e a análise da estrutura da base de conhecimentos dependem do paradigma adotado para o desenvolvimento do sistema especialista e dos aspectos que o engenheiro de conhecimentos deseja verificar. Dessa forma, a validação da base de conhecimentos se torna muito ampla para enfocar e por si só se constitui numa área apaixonante de pesquisa.

A avaliação de desempenho de um sistema especialista pode ser vista como uma medida do grau de similaridade do comportamento do sistema ao do próprio especialista do domínio. Aqui, a questão principal é verificar se o sistema consegue emular o comportamento do especialista. Neste caso, é necessário comparar a hipótese diagnóstica ou de classificação (*output*) oferecida pelo sistema com o diagnóstico ou classificação do próprio especialista. A avaliação de desempenho de um sistema independe do paradigma adotado para o desenvolvimento do sistema, e por si só se constitui num único objetivo de análise. Por isso, decidiu-se neste trabalho ilustrar este aspecto.

## 5.1 Avaliação de Desempenho

Para realizar de forma objetiva a avaliação de desempenho de um sistema especialista é necessário dispor de um conjunto com  $n$  casos do domínio de aplicação. Este conjunto de casos é chamado de base de teste do sistema. Na base de teste, as evidências (*input*) e a classificação feita pelo especialista devem estar explicitados para cada um dos  $n$  casos da base de teste. Este conjunto de casos deve ser submetido ao sistema especialista que oferecerá uma hipótese diagnóstica ou de classificação (*output*) para cada caso. Ao fazer uma comparação entre a resposta oferecida pelo sistema e a classificação feita pelo

especialista, obtém-se a percentagem de acerto do sistema. Ou ainda, pode-se raciocinar de forma complementar e obter a taxa de erro de classificação. Em ambas as abordagens deve ser obtido intervalo de confiança (IC) para o percentual em questão. Por outro lado, deve-se analisar o conhecimento que o sistema possui utilizando-se o teste  $\chi^2$ , tanto para o conhecimento global do sistema quanto para avaliar seu desempenho em relação a cada uma das hipóteses diagnósticas. Estes conceitos teóricos estão apresentados a seguir.

### a) Intervalo de Confiança para Percentual

Para avaliar um SE é submetido um conjunto (amostra) de  $n$  casos de teste com o objetivo de estimar a taxa de acerto do sistema (população). Os valores obtidos na amostra são estimativas dos valores populacionais, e a estimação destes é feita por procedimentos estatísticos denominados *Intervalos de Confiança*. A medida estatística *Intervalo de Confiança* é apresentada de maneira complementar às estimativas (*estatísticas*) calculadas dos valores populacionais e busca estimar limites de um intervalo que deve conter o parâmetro populacional considerando um nível de confiança pré-definido pelo pesquisador. Uma vez definido o parâmetro de estudo e calculada sua *estatística*, faz-se sempre necessária a informação complementar de seu *Intervalo de Confiança*, sendo esta uma importante forma de inferência no sentido de compreender o fenômeno em estudo. A seguir são dados alguns conceitos estatísticos necessários para o desenvolvimento deste ítem.

**Parâmetro:** alguma característica relativa às unidades da população em estudo<sup>1</sup>. Por exemplo: a taxa de erro de um determinado sistema especialista.

**Estatística:** alguma característica relativa às unidades da amostra, portanto, obtida a partir dos dados coletados. Por exemplo: a taxa de erros de um determinado sistema obtida em uma amostra de casos (base de teste) selecionados do domínio de aplicação.

As estatísticas (amostra) são utilizadas como informação sobre os parâmetros (população), e neste sentido são chamadas de estimadores. O quadro 5.1 apresenta uma notação para fazer a distinção quando se tratar de uma ou outra característica.

---

<sup>1</sup> A partir de agora chamada apenas de população.

Para ilustrar a estimação de parâmetros veja o seguinte exemplo:

Considerando uma base de teste com 100 casos representativos do domínio de aplicação e que foram submetidos ao sistema especialista obteve-se uma taxa de erro de classificação  $p = 7\%$ . Que declaração pode ser feita sobre a proporção de erro do sistema especialista?

Quadro 5.1 - Notação para características populacionais e da amostra

Característica de Interesse	Notação	
	População	Amostra
Proporção	P	p
Tamanho	N	n

Note que estas estatísticas amostrais trazem informações sobre a taxa (proporção) de ocorrência de erro ( $P$ ) para os casos da base de teste submetidos ao sistema. Porém, não se deve simplesmente dizer que os parâmetros populacionais são iguais aos valores obtidos na amostra, isto é, declarar que  $P = 7\%$ . Deve-se considerar que se fosse submetido ao sistema uma outra base de teste de 100 casos, sob as mesmas condições, as estatísticas amostrais não necessariamente teriam exatamente os mesmos valores para  $p$ . Desta forma, a partir das estatísticas amostrais deve-se obter um intervalo que deve conter o parâmetro populacional, considerando que essas estatísticas, por sua vez, são também variáveis aleatórias e devem ser consideradas à luz de um modelo probabilístico.

Os intervalos construídos a partir das estatísticas amostrais são chamados de intervalos de confiança (IC). No exemplo acima deve-se construir um IC para  $P$ , a proporção ou taxa de erro de classificação do sistema especialista.

Estando em busca da generalização da taxa (proporção)  $p$  de 7% de erro de classificação do sistema especialista para a taxa (proporção)  $P$  para os outros casos novos a serem submetidos ao sistema, precisa-se então associar a estatística  $p$  ao parâmetro  $P$ .

A taxa (proporção)  $p$  na amostra é obtida pela seguinte expressão:

$$p = \frac{n_e}{n}$$

onde:

$n_e$  é o número de casos classificados erroneamente pelo sistema e  $n$  é o tamanho (número de casos) da base de teste.

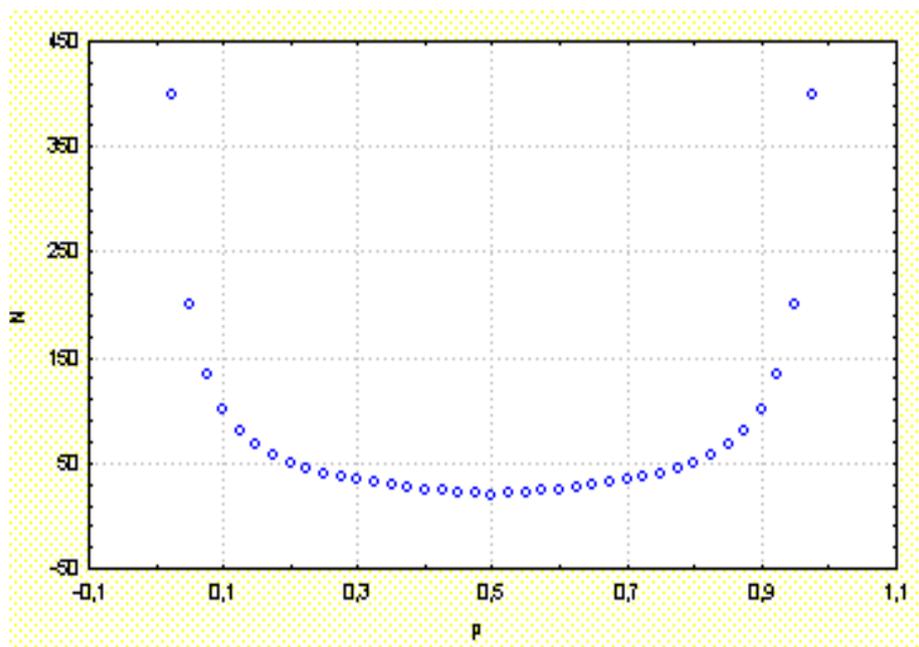
Você esperaria que se fossem obtidas diferentes bases de teste de mesmo tamanho e sob as mesmas condições a taxa (proporção) amostral  $p$  fosse a mesma, isto é, igual a 7% ? A priori pode-se afirmar que não, por quê? Porque, genericamente, o número de casos classificados com erro na amostra é uma variável aleatória que pode assumir os valores inteiros entre zero e  $n$ ; assim a taxa (proporção) amostral  $p$  é também uma variável aleatória com valores entre zero e 1 (ou, similarmente, entre 0 e 100%). Dessa forma a taxa (proporção) amostral  $p$  deve ter seu comportamento descrito por um modelo probabilístico.

Sob as seguintes suposições se pode assumir que o modelo Normal pode descrever o comportamento da taxa amostral  $p$ : a) que a população em estudo é muito grande, de tal forma que seja  $P$  a probabilidade de qualquer caso da amostra ser mal classificado; b) os casos da amostra são independentes; c) a amostra é grande<sup>2</sup>. Estas variáveis linguísticas, utilizadas em Estatística, nem sempre são quantificáveis, porém a figura 5.1 busca ilustrar a relação tamanho mínimo ( $n$ ) da amostra para diferentes valores de  $P$ , de tal forma a supor o modelo Gaussiano (ou Normal) caracteriza o comportamento da taxa (proporção) amostral  $p$ .

Figura 5.1 - Tamanho Mínimo da Amostra para Utilização do Modelo Normal para a Taxa ou Proporção Amostral  $p$

---

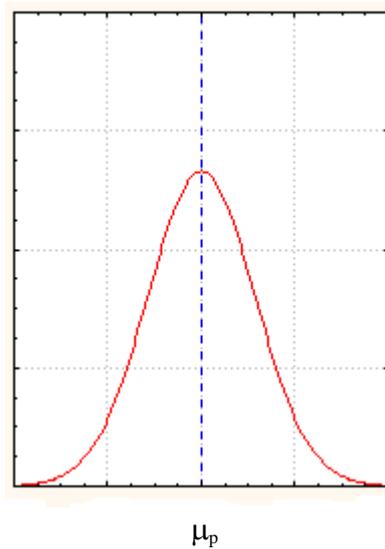
<sup>2</sup> Ver figura 5.1- Aqui adotou-se que o modelo binomial pode ser aproximado pelo modelo normal quando ambos  $n.p$  e  $n.(1-p)$  são maiores ou iguais a 5. Alguns autores sugerem valores maiores ou iguais a 10 e outros ainda sugerem valores maiores ou iguais a 15.



O tamanho ( $n$ ) da amostra para atender a suposição de normalidade para a taxa amostral  $p$  depende do valor que se estima, a priori, para a taxa (proporção) populacional  $P$ . Assim, ao estimar que  $P = 0.30$  então, no gráfico, o tamanho mínimo da amostra seria 35 casos. Observe que, à medida que o valor estimado de  $P$  difere de 0.50, maior deve ser o tamanho mínimo ( $n$ ) da amostra para a utilização do modelo Normal para a taxa amostral  $p$ . Ao final deste ítem encontra-se um procedimento para estimar o tamanho da amostra com base em intervalos de confiança.

O modelo Normal (ou Gaussiano) é totalmente especificado quando se conhece a média e o desvio padrão da variável que está sendo representada pelo modelo (figura 5.2). Neste caso, é utilizado para descrever o comportamento da taxa amostral  $p$ , cuja média e desvio padrão são dados por:

Figura 5.2 - Distribuição Normal para o percentual amostral  $p$



$$\mu_p = P \quad (5.2)$$

$$\sigma_p = \sqrt{\frac{P \cdot (1 - P)}{n}}$$

Uma vez determinado um modelo probabilístico para a taxa (percentual) amostral  $p$ , pode-se obter um intervalo que deve conter a taxa (percentual) populacional  $P$ , com um nível de confiança especificado, considerando o erro amostral<sup>3</sup> próprio do processo estatístico de inferência, da seguinte forma:

$$IC = p \pm \text{erro amostral} \quad (5.3)$$

onde  $IC$  = Intervalo de Confiança,  $p$  = taxa obtida na amostra e o erro amostral é calculado a partir do modelo Normal e nível de confiança especificado.

Os estudos, que tem por base os dados de uma amostra, têm uma chance de erro em suas conclusões sobre a população; esta chance de erro é própria do processo de indução amostra-população e é declarada nos resultados estatísticos. Neste item, onde se faz a estimação de  $P$  considerando que a probabilidade de erro é  $\alpha$ , então a probabilidade de

<sup>3</sup> Erro amostral é a diferença entre o valor da estatística amostral e o parâmetro populacional estimado.

acerto nas conclusões estatísticas é  $(1 - \alpha)$  e é chamada nível de confiança. Quando a análise estatística dos dados amostrais é feita por procedimentos de testes de hipóteses, a chance de erro, ao afirmar a hipótese de pesquisa, é chamada de nível de significância  $\alpha$ . Valores usuais<sup>4</sup> para  $\alpha$  são 0.05 ou 0.01 ou 0.001. A escolha de um valor para  $\alpha$  depende dos recursos disponíveis para a realização da pesquisa e da confiabilidade necessária aos resultados. Note-se que, para um estudo por amostragem ter um pequeno erro amostral, a amostra coletada deve ser grande; no limite pode-se dizer que quando  $n \rightarrow N$  então o erro amostral tende para zero.

Assim o erro amostral é obtido pela seguinte expressão:

$$\text{erro amostral} = z_{\alpha} \cdot \sigma_p \quad (5.4)$$

onde o valor de  $\sigma_p$  é estimado considerando a proporção amostral  $p$  no lugar de  $P$  na fórmula (5.2). Na tabela 5.2 são mostrados alguns valores de  $z_{\alpha}$  para diferentes valores de  $\alpha$ .

Tab 5.2 - Valores de  $z_{\alpha}$

Valores de $\alpha$	0.10	0.05	0.01	0.001
Valores de $z_{\alpha}$	1.64	1.96	2.58	3.30

Para mostrar a obtenção do intervalo de confiança para  $P$ , considere que na pesquisa exemplificada foi adotado um nível de confiança de 0.95 (portanto  $\alpha = 0.05$ ). E para os 100 casos da base de teste observou-se que a taxa de erro foi  $p = 0.07$ , tem-se:

$$\text{erro amostral} = 1.96 \times \sqrt{\frac{0.07 (1 - 0.07)}{100}}$$

$$\text{erro amostral} = 0.05$$

Assim o intervalo de confiança para  $P$  fica igual a

$$\text{IC} = 0.07 \pm 0.05$$

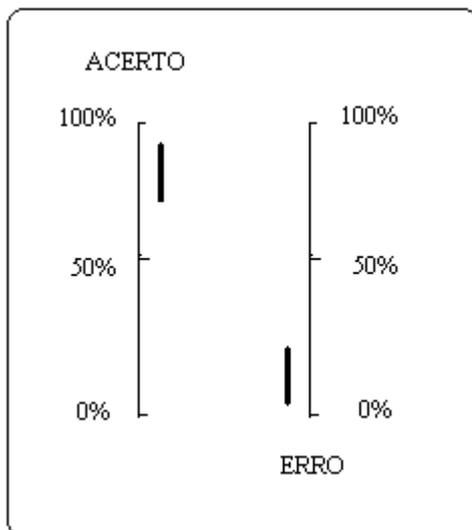
obtendo-se os limites inferior e superior para o IC:

$$0.07 - 0.05 = 0.02 \quad \text{e} \quad 0.07 + 0.05 = 0.12$$

<sup>4</sup> Em estudos descritivos é aceito, pela comunidade científica, um valor de  $\alpha$  igual a 0.10

ou seja em termos percentuais obtém-se  $IC=[ 2.0\% ; 12.0\% ]$ .

Figura 5.3 - Intervalo de Confiança para a Taxa (percentual) de Acerto e de Erro



Desta forma, a partir dos dados amostrais (base de teste) e a um nível de confiança de 0.95 (ou grau de certeza de 95%), conclui-se que, embora se tenha estimado que a proporção de casos mal classificados na base de teste submetida ao sistema especialista seja de 7%, a taxa de erro do sistema é algum valor entre 2.0% e 12.0% . Assim assume-se que o sistema tem um bom desempenho.

### b) Validade Interna do Sistema

O diagnóstico ou classificação oferecida pelo sistema quando comparada com a classificação do especialista deveria identificar corretamente casos e não casos de uma hipótese diagnóstica  $H_i$ . Quando tal não ocorre, então um diagnóstico positivo é encontrado em alguns casos que não pertencem àquela hipótese diagnóstica, são os chamados falsos-positivos; enquanto que alguns casos da hipótese  $H_i$  são perdidos, devido aos resultados falso-negativos. Enfrenta-se, pois problemas na *validade interna* do sistema.

Têm-se as seguintes medidas de validade interna do sistema (Quadro 5.1).

Quadro 5.1 - Medidas de Validade Interna do Sistema para uma determinada Hipótese Diagnóstica  $H_i$ .

Diagnóstico do Sistema	Diagnóstico do Especialista (Padrão Ouro)		TOTAL
	<i>Positivo</i>	<i>Negativo</i>	
<i>Positivo</i>	$N_{11}$	$N_{12}$	$NS_p$
<i>Negativo</i>	$N_{21}$	$N_{22}$	$NS_n$
<b>TOTAL</b>	$NE_p$ <b>SENS</b>	$NE_n$ <b>ESP</b>	<b>n</b>

**b.1) SENSIBILIDADE:** definida como a probabilidade (ou capacidade) do sistema gerar resultado positivo, dado o caso pertencer à hipótese diagnóstica  $H_i$  em questão ( é a capacidade do sistema detectar casos positivos da hipótese diagnóstica  $H_i$ ).

$$SENS = \text{Prob} (DS_{\text{positivo}} | DE_{\text{positivo}}) = N_{11} / NE_p$$

onde

$DS_{\text{positivo}}$  denota o evento o Diagnóstico do Sistema é positivo,  
 $DE_{\text{positivo}}$  denota o evento o Diagnóstico do Especialista é positivo.

A *sensibilidade* do sistema responde à questão prática de quantos casos positivos podem ser identificados por um diagnóstico positivo do sistema, considerando a hipótese diagnóstica  $H_i$ .

Embora não haja um nível de sensibilidade que determine a validade interna do sistema sugere-se que valores em torno de 80% ou mais seriam desejáveis. É importante ressaltar que a baixa sensibilidade leva à perda de casos candidatos a alguma ação a ser tomada, o

que pode levar a longo prazo a uma situação global de descontrolo no domínio de aplicação.

**b.2) ESPECIFICIDADE:** definida como a probabilidade do sistema gerar um diagnóstico negativo, dado que o caso não pertence à hipótese diagnóstica  $H_i$  em questão (é a capacidade do sistema detectar casos negativos da hipótese diagnóstica).

$$ESP = \text{Prob} (DS_{\text{negativo}} | DE_{\text{negativo}}) = N_{22} / NE_n$$

onde

$DS_{\text{negativo}}$  denota o evento o Diagnóstico do Sistema é negativo,  
 $DE_{\text{negativo}}$  denota o evento o Diagnóstico do Especialista é negativo.

A *especificidade* avalia o desempenho do sistema e responde a outra questão prática: quantos casos que não pertencem à hipótese diagnóstica serão confirmados por um diagnóstico negativo do sistema? Esta resposta é de interesse enquanto medida racionalizadora de custos no domínio pesquisado.

**b.3) VALOR PREDITIVO POSITIVO DO SISTEMA:** definido como a probabilidade do caso pertencer à hipótese diagnóstica em questão dado o diagnóstico positivo do sistema.

$$VPP = \text{Prob} (DE_{\text{positivo}} | DS_{\text{positivo}}) = N_{11} / NS_p$$

Neste caso, deseja-se saber com que grau de certeza o caso pertence à hipótes diagnóstica quando o diagnóstico oferecido pelo sistema é positivo

**b.4) VALOR PREDITIVO NEGATIVO DO SISTEMA:** definido como a probabilidade do caso não pertencer à hipótese diagnóstica  $H_i$  dado um diagnóstico negativo do sistema.

$$VPN = \text{Prob} (DE_{\text{negativo}} | DS_{\text{negativo}}) = N_{22} / NS_n$$

O *valor preditivo negativo* do sistema ou o *valor preditivo de um diagnóstico negativo pelo sistema* responde à questão prática do grau de certeza de que não ter nenhuma ação em relação aquele caso é a decisão mais adequada.

Na prática, uma vez entendidas estas noções, se um sistema possui uma **especificidade alta**, então um **diagnóstico positivo** informa a **favor** da hipótese diagnóstica  $H_i$  em questão. E se um sistema possui uma **alta sensibilidade** então um **resultado negativo** informa **contra** o diagnóstico da hipótese  $H_i$ . Seria esta uma leitura alternativa de especificidade e sensibilidade, raciocinando em forma de *valor preditivo positivo* e *valor preditivo negativo*, respectivamente.<sup>5</sup>

Um outro conceito seria a **validade externa** de um sistema especialista, ou seja, *sua habilidade de ter resultados similares de desempenho quando utilizado em domínios semelhantes ao domínio de aplicação*. Por exemplo, um sistema de apoio ao diagnóstico de desnutrição infantil desenvolvido na região sul do país deveria ser adequado para utilização na região norte.

#### **b.5) RAZÕES DE VEROSSIMILHANÇA (“LIKELIHOOD RATIOS”)**

Ainda na validação interna do sistema é desejável que para uma hipótese  $H_i$  sejam feitos diagnósticos que forneçam tantos resultados positivos quanto possível, com o mínimo de diagnósticos falsos-positivos. O mesmo raciocínio aplica-se aos resultados negativos. Um dos métodos para abordar este problema é através do cálculo de *razões de verossimilhança*.

A *razão de verossimilhança* (também interpretada como *razão de probabilidades*) é a probabilidade de que um diagnóstico oferecido pelo sistema seria esperado em um caso pertencente à hipótese diagnóstica  $H_i$  em questão, comparada com a probabilidade de que o mesmo diagnóstico seria esperado em um caso que não pertence àquela hipótese diagnóstica.

$$\mathbf{RVD}_{\text{positivo}} = \mathbf{sensibilidade} / (1 - \mathbf{especificidade}) = \mathbf{SENS} / (1 - \mathbf{ESP})$$

Quanto maior a razão de verossimilhança de um diagnóstico positivo, melhor o desempenho do sistema.

---

<sup>5</sup> Para completar esta questão de validação, seria necessário ao leitor buscar informações sobre as curvas ROC, e quanto à validade externa, informações sobre o coeficiente Kappa.

Seguindo o mesmo raciocínio, deve-se desenvolver um sistema, cujos resultados falsos-negativos (1 - sensibilidade) devem ser obtidos de tal maneira que um resultado negativo seja mais provável de ser um verdadeiro resultado negativo (especificidade). Obtém-se desta maneira a avaliação da *razão de verossimilhança de um resultado de teste negativo*:

$$\mathbf{RVD_{negativo} = (1 - sensibilidade) / especificidade = (1 - SENS) / ESP}$$

Neste caso, quanto menor a razão de verossimilhança de um diagnóstico negativo, melhor o desempenho do sistema.

### **b.6) ODDS RATIO**

Pode ser utilizado o conceito de *Odds ratio* ou razão de chances para avaliar o desempenho de um sistema. Assim considerando a taxa de erro  $p_e$  e a taxa de acerto  $p_a$  obtém-se a razão entre estas duas chances:

$$\mathbf{ODDS = p_a / p_e}$$

Estimando-se a *Odds ratio* para um sistema que apresentou uma taxa de erro de 7% então tem-se  $ODDS = 0.93 / 0.07$  resultando  $ODDS = 13.3$ , neste exemplo o sistema acerta muito mais do que erra, desta forma pode ser considerado com um bom desempenho. Na Tabela 5.3 encontra-se ilustrada a *Odds ratio* para diferentes valores de taxa de erro.

Tabela 5.3 - *Odds ratio* e Desempenho do Sistema

Taxa de Erro de Classificação	<i>Odds Ratio</i>	Desempenho do Sistema
maior que 20%	menor que 4	insatisfatório
20 %	4.0	satisfatório
15 %	5.7	razoável
10 %	9.0	bom
5 %	19.0	muito bom
1%	99.0	excelente

Note que parece ser razoável especificar que se o sistema erra a classificação em mais que 20 % dos casos seu desempenho não seja satisfatório. Dessa forma assume-se que se a *Odds ratio* for maior ou igual a 4 o sistema apresenta um desempenho satisfatório; e

quanto maior for esta razão melhor será o desempenho do sistema. Assim, neste trabalho propõe-se a classificação do desempenho do sistema conforme ilustrado na Tabela 5.3.

## 5.2 Tamanho da Amostra ( Base de Teste )

Em pesquisas de um modo geral uma das preocupações é a definição de um plano de amostragem, com o objetivo de obter uma amostra representativa da população em estudo. Genericamente pode-se dizer que esta representatividade pode ser vista sob dois aspectos: o comportamento das variáveis e o tamanho (n) da amostra. É um falso conceito que tamanho n da amostra é um valor em torno de 10% da população, ou mesmo que n seja igual a 30. O tamanho (n) da amostra depende dos procedimentos de análise dos dados, que serão utilizados na pesquisa, e da variabilidade dos dados; assim não há um valor predefinido para estimar n.

Aqui é feita a determinação de n, considerando a utilização do procedimento de estimação da taxa de erro de classificação em um sistema especialista (estimação de proporção). Lembre que neste item tem-se como objetivo geral avaliar o desempenho do sistema especialista, considerando sua taxa de erro de classificação. Assim, a partir da taxa de erro obtida com os casos de uma base de teste deve-se proceder a inferência para o domínio de aplicação do sistema especialista. O domínio de aplicação do sistema é aqui considerado como a população em estudo.

A estimação do tamanho (n) da amostra (base de teste) para obter um intervalo de confiança para a taxa (proporção) P populacional ou para o domínio em estudo, pode ser feita por meio da seguinte estratégia:

- 1) especificar o nível de confiança adotado na pesquisa;
- 2) na tabela 5.2.2 obter o valor  $z_{\alpha}$  ;
- 3) especificar o erro amostral máximo admitido na pesquisa ( $e_{\max}$ );
- 4) fazer uma estimativa, a priori, do parâmetro P na população;
- 5) estimar n utilizando a seguinte fórmula:

$$n = \left( \frac{z_{\alpha}}{e_{\max}} \right)^2 . P . (1 - P)$$

A estimativa, a priori, do parâmetro P é feita pelo pesquisador quando este pode avaliar qualitativamente a taxa de erro do sistema especialista, ou através de uma amostra piloto

de teste. No entanto, quando isto não é possível, podemos superestimar  $n$  ao adotarmos que  $P$  seja igual a 0.50 chegando à seguinte fórmula:

$$n = \left( \frac{z_{\alpha}}{2 \cdot e_{\max}} \right)^2$$

Para exemplificar, considere que estamos delineando uma pesquisa que tem como objetivo estimar a taxa  $P$  de erro de classificação de um sistema especialista. Então, seguindo os itens anteriormente descritos:

- 1) adotando-se nesta pesquisa um nível de confiança de 0.95
- 2) na tabela 5.2.2 para este nível de confiança determina-se  $z$  igual a 1.96
- 3) nesta pesquisa adota-se um erro amostral máximo igual 5 %
- 4) considerando que não se dispõe de informação a priori sobre  $P$ , então utilizar-se-á a fórmula <sup>6</sup> para estimar o tamanho ( $n$ ) da amostra:

$$n = \left( \frac{1,96}{2 \times 0,05} \right)^2 = 385 \text{ casos}$$

Se o número  $N$  de casos do domínio de aplicação não for grande então pode-se corrigir o valor de  $n$  anteriormente calculado, utilizando a seguinte fórmula:

$$n_f = \frac{n}{1 + \left( \frac{n}{N} \right)}$$

onde  $N$  é o tamanho da população em estudo ou número de casos do domínio de aplicação.

Na Tabela 5.4 ,a seguir, encontra-se ilustrado o tamanho  $n$  da amostra (base de teste) para diferentes valores da taxa de erro. Note que o tamanho da base de teste é bastante sensível à taxa de erro esperada e à especificação do erro amostral admitido.

Considerando-se a situação de máxima entropia, isto é, a taxa de erro é igual à taxa de acerto ( 50 %), e um erro amostral de 10 % obtém-se os seguintes tamanhos da base de teste : 68 ; 96 e 167 casos , correspondentes a um nível de confiança igual a 90 % , 95 % e 99 % , respectivamente.

---

<sup>6</sup> Note-se que, neste exemplo a estratégia de adotar a taxa de erro igual a 0.50 indica uma situação de máxima entropia, isto é, o sistema especialista não sabe nada. Ele acerta e erra a classificação com igual chance.

Tabela 5.4 - Tamanho da Base de Teste para Diferentes Valores de Taxa de Erro Esperada

Taxa de Erro Esperada	Erro Amostral Máximo	Tamanho (n) da Base de Teste*
20 %	10 %	43 / 62 / 107
	5 %	172 / 246 / 426
	3 %	478 / 683 / 1184
10 %	10 %	25 / 35 / 60
	5 %	97 / 138 / 240
	3 %	269 / 385 / 666
5 %	5 %	51 / 73 / 126
	3 %	192 / 203 / 352

\* Estes valores são para um nível de confiança igual a 90 %, 95 % e 99% , respectivamente.

Finalmente, a base de teste deveria ser do tamanho n estimado neste item para garantir a representatividade em tamanho da base. Por outro lado, deve-se também garantir a representatividade em relação à qualidade dos casos da base de teste, isto é, estes devem ser selecionados adequadamente para compor a base, de forma que sejam representativos da realidade encontrada no domínio de aplicação.

### 5.3 Exemplo de Aplicação

Para ilustrar a aplicação destes conceitos será considerado o Sistema Especialista Probabilístico para Apoio ao Diagnóstico de Edema Subcutâneo Localizado.

Esse sistema realiza diagnóstico diferencial entre dois tipos de edema: alergia e celulite, conforme descrito anteriormente no item 5.1. Supondo que foi utilizada uma base de teste com 100 casos e os resultados dos diagnósticos oferecidos pelo sistema e pelo especialista do domínio de aplicação estão dispostos na Tabela 5.5.

Tabela 5.5 - Distribuição dos Diagnósticos do Especialista e do Sistema Especialista

Diagnóstico do Sistema Especialista	Diagnóstico do Especialista do Domínio de Aplicação (Padrão Ouro)		TOTAL
	<i>Alergia</i>	<i>Celulite</i>	
<i>Alergia</i>	<b>66</b>	3	69
<i>Celulite</i>	4	<b>27</b>	31
<b>TOTAL</b>	70	30	100

a) Qual a taxa de erro de classificação do sistema especialista?

Nesta tabela observa-se que sete casos foram mal classificados do total de 100 casos submetidos ao sistema. Nesta amostra a taxa de erro de classificação é igual a 7 %. A partir desta informação amostral, como foi visto no item 5.2.1.1, pode-se obter um intervalo de confiança para a taxa de erro do sistema. Assim pode-se afirmar, a um nível de confiança de 0.95, que a taxa de erro do sistema está entre 2% e 12% .

b) O sistema especialista tem conhecimento sobre o domínio de aplicação, isto é, tem conhecimentos sobre edema subcutâneo localizado?

Esta pergunta já foi respondida quando estimamos a taxa de erro do sistema. Pois se o sistema nada soubesse sobre o domínio de aplicação então a taxa de erro deveria ser alta.

c) Verifique se o sistema possui validade interna.

O conceito validade interna refere-se à capacidade do sistema realizar diagnóstico diferencial. Para averiguar a validade interna do sistema deve ser realizada uma análise para cada uma das hipóteses diagnósticas individualmente. Devemos considerar o diagnóstico do próprio especialista como o diagnóstico de referência, isto é, o padrão ouro. Neste sistema de diagnóstico de edemas devem ser analisadas as hipóteses diagnósticas de alergia e de celulite, que são as categorias de classificação consideradas.

### c.1. Diagnóstico de Alergia

A validade interna do sistema para realizar o diagnóstico de alergia será averiguada a partir dos dados da Tabela 5. 6 enfocados como mostra a tabela 5.7, de onde são obtidos os seguintes indicadores: sensibilidade, especificidade, valor preditivo positivo do sistema, valor preditivo negativo do sistema e Likelihood *ratios*.

Tabela 5.6 - Comparação dos Diagnósticos do Especialista e do Sistema Especialista para a Hipótese Diagnóstica Alergia

Diagnóstico do Sistema Especialista	Diagnóstico do Especialista do Domínio de Aplicação (Padrão Ouro)		TOTAL
	<i>Alergia</i> <sup>+</sup>	<i>Alergia</i> <sup>-</sup>	
<i>Alergia</i> <sup>+</sup>	<b>66</b>	3	69
<i>Alergia</i> <sup>-</sup>	4	<b>27</b>	31
<b>TOTAL</b>	70	30	100

#### c.1.1. Sensibilidade

Este indicador estima a probabilidade do sistema detectar que um paciente tem alergia se o paciente realmente tiver alergia, sendo igual a :

$$\text{SENS} = (66 / 70) = 0.943$$

Isto é, 94.3% dos pacientes com alergia serão classificados pelo sistema como portadores de alergia.

#### c.1.2. Especificidade

Este indicador estima a probabilidade do sistema detectar que um paciente não tem alergia se o paciente realmente não tiver alergia, sendo igual a:

$$\text{ESP} = (27 / 30) = 0.900$$

Isto é, 90.0% dos pacientes sem alergia serão diagnosticados pelo sistema como não portadores de alergia.

### c.1.3. Valor Preditivo Positivo do Sistema

Este indicador estima a probabilidade de um paciente ser portador de alergia se o sistema diagnosticar que tem alergia, sendo igual a:

$$\text{VPP} = (66 / 69) = 0.957$$

Isto é, se o sistema diagnosticar que um paciente tem alergia então a probabilidade de que realmente o paciente seja portador de alergia é 95.7% .

### c.1.4. Valor Preditivo Negativo do Sistema

Este indicador estima a probabilidade de um paciente não ser portador de alergia se o sistema diagnosticar que não tem alergia, sendo igual a:

$$\text{VPN} = (27 / 31) = 0.871$$

Isto é, se o sistema diagnosticar que um paciente não tem alergia então a probabilidade de realmente o paciente não ser portador de alergia é 87.1% .

### c.1.5. *Likelihood ratio* ou Razão de Verossimilhança

Aqui devemos obter a razão de verossimilhança para um diagnóstico positivo (RVD positivo) e para um diagnóstico negativo (RVD negativo) de alergia, assim:

$$\text{RVD positivo} = 0.943 / (1 - 0.900) = 9.430$$

$$\text{RVD negativo} = (1 - 0.943) / 0.900 = 0.063$$

### c.1.6. *ODDS ratio*

Esta medida indica a razão entre a probabilidade de acertar e a de errar quando o sistema realiza o diagnóstico de alergia, sendo igual a:

$$\text{ODDS} = (66/70) / (4/70) = 16.5$$

Se avaliarmos os indicadores obtidos de validade interna podemos dizer que o sistema um desempenho de bom a muito bom quando faz um diagnóstico de alergia.

Ao repetir os cálculos para os indicadores do diagnóstico de celulite e dispor os resultados na Tabela 5.7, podemos realizar a avaliação da validade interna do sistema especialista para o diagnóstico de edemas subcutâneos.

Tabela 5.7 - Indicadores de Validade Interna do Sistema Especialista

<b>Indicadores de Validade Interna</b>	<b>Alergia</b>	<b>Celulite</b>
Sensibilidade	0.943	0.900
Especificidade	0.900	0.943
Valor Preditivo Positivo	0.957	0.871
Valor Preditivo Negativo	0.871	0.957
Razão de Verossimilhança Positiva	9.430	15.789
Razão de Verossimilhança Negativa	0.063	0.106
<i>ODDS ratio</i>	16.500	9.000

Desta forma, concluímos que o sistema apresenta um desempenho muito bom para realizar diagnóstico para pacientes portadores de alergia e um desempenho razoável para os pacientes portadores de celulite. Portanto, deve ser melhorado o conhecimento na base de conhecimentos no que se refere ao diagnóstico de celulite.

Considerando que um sistema especialista pretende emular o comportamento de um especialista num domínio de aplicação então é de fundamental importância que o desempenho do sistema e sua validade interna sejam estatisticamente avaliados.



## 6 Referências

- Albuquerque, L. **Sistema Especialista de Apoio à Nutrição Enteral Pediátrica – SANEP**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Depto. de Informática e de Estatística, UFSC, 2001.
- Bender, Edward A. **Mathematical Methods in Artificial Intelligence**. California, Los Alamitos: IEEE Computer Society Press, 1996.
- Brignolli, J. **Modelo Híbrido Difuso Probabilístico**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Depto. de Informática e de Estatística, UFSC, 2001.
- Cowell, R.G. et al. **Probabilistic Networks and Expert Systems**. New York: Springer-Verlag, 1999, 321p.
- Eells, E. & Skyrms, B. **Probability and Conditionals: Belief revision and rational decision**. New York: Cambridge University, 1994, 207 p.
- Gaag, Linda C. **Bayesian Belief Networks: Odds and Ends**. The Computer Journal, vol 39, nº 2, 1996, p 97-113.
- Gelman, A & Carlin, John B. & Stern, Hal S. & Rubin, Donald B. **Bayesian Data Analysis**. London: Chapman Hall, 1996, 526 p.
- Geszyczter, M.B. **Modelagem Multiagente escalável para Integração de Sistemas Especialistas**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Depto. de Informática e de Estatística, UFSC, 2003.
- Köehler, C. **Uma Abordagem Bayesiana para Sistemas Especialistas**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Depto. de Informática e de Estatística, UFSC, 1998.
- Losi, N. A. **ABS-Bayes: Sistema Especialista Probabilístico para Apoio ao Diagnóstico de Absenteísmo**. Dissertação de Mestrado, Programa de Pós-Graduação em Computação, Depto. de Informática e de Estatística, UFSC, 2003.
- Mendes, R. S. **Abordagem Bayesiana para Redes sem Fio Cognitivas**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Depto. de Informática e de Estatística, UFSC, 2010.
- Nassar, Sílvia M. **A Estatística como Apoio à Inteligência Artificial: Sistemas Especialistas Probabilísticos**. In: Estatística e Informática: um processo interativo entre duas ciências. Trabalho apresentado no Concurso para Professor Titular, Departamento de Informática e de Estatística, Centro Tecnológico, Universidade Federal de Santa Catarina, 1998, 128p.
- Neapolitan, Richard E. **Probabilistic Reasoning in Expert Systems**. New York: Wiley Interscience, 1990, 433 p.
- Pasini, H. **Sistema Especialista Probabilístico para Apoio ao Diagnóstico de Potencial Econômico - SEPE**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Depto. de Informática e de Estatística, UFSC, 2002.
- Pearl, Judea. **Probabilistic Reasoning in Intelligent Systems: networks of plausible inference**. California, San Mateo: Morgan Kaufmann Publishers, 1988, 552 p.
- Penz, C. A. **Procedimentos para Prover Confiabilidade ao Uso de Inteligência Artificial em Ensaios de Desempenho de Compressores Herméticos de Refrigeração**. Tese de Doutorado, Programa de Pós-Graduação em Engenharia Mecânica, Depto. de Engenharia Mecânica, UFSC, 2011.

- Russell, Stuart & Norvig, Peter. **Artificial Intelligence: A Modern Approach**. New Jersey: Prentice Hall, 2005, 932 p.
- Rödter, Wilhelm & Kopittke, Bruno & Kulmann, Friedhelm. **Sistemas Especialistas Probabilísticos**. Texto para ensino à distância feito em cooperação com a FernUniversität Hagen, 1997, 60 p.
- Rovaris Neto, E. **Sistema Especialista de Apoio à Gestão da Evasão Escolar – E-Bayes**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Depto. de Informática e de Estatística, UFSC, 2002.
- Simões, P.W.T.A. **Sistema de Apoio na Avaliação da Falência do Crescimento Infantil – SACI**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Depto. de Informática e de Estatística, UFSC, 2001.
- Stein, C. **Sistema Especialista Probabilístico: base de conhecimento dinâmica**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Depto. de Informática e de Estatística, UFSC, 2000.
- Toledo, R.V. **Sistema de Apoio ao Diagnóstico Diferencial de Cefaléia**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Informática Aplicada, PUC-Paraná, 2000.
- Tibiriçá, C.A. **Uma Abordagem Híbrida Fuzzy-Bayesiana para Modelagem de Incertezas**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Depto. de Informática e de Estatística, UFSC, 2005.
- Venicius, M. **Agente Bayesiano de Apoio à Vigilância de Infecção Hospitalar - SAVIH**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Depto. de Informática e de Estatística, UFSC, 2002.
- Veronez, C. **Baseline Bayesiana para Gerência de Tráfego em Redes de Computadores**. Dissertação de Mestrado, Programa de Pós-Graduação em Ciência da Computação, Depto. de Informática e de Estatística, UFSC, 2000.

## ANEXOS

## ANEXO 1 - Endereços sobre “Bayesian Networks”

### Palavras chave:

**Probabilistic Networks**  
**Bayesian Networks**  
**Probabilistic Expert Systems**

### a) Informações sobre Redes Probabilísticas ou Bayesianas

<http://bayes.stat.washington.edu/almond/belief.html>  
<http://ca.berkeley.edu/~murphyk/Bayes/bayes.html>  
<http://www.afit.af.mil/Schools/EM/AI>  
<http://www.auai.org/>  
<http://www.cs.auc.dk/research/DSS>  
<http://www.maths.nott.ac.uk/hsss>  
<http://www.research.microsoft.com/research/dtg>

### b) Softwares para Redes Probabilísticas ou Bayesianas

<http://has.cmu.edu/html/departments/philosophy/TETRAD/tetrad.html>  
<http://ca.berkeley.edu/~murphyk/Bayes/bnsoft.html>  
<http://kmi.open.ac.uk/projects/bkd>  
[http:// \[www.city.ac.uk/~rgc\]\(http://www.city.ac.uk/~rgc\)](http://www.city.ac.uk/~rgc)  
[http:// \[www.cs.cmu.edu/~javabayes/Home/\]\(http://www.cs.cmu.edu/~javabayes/Home/\)](http://www.cs.cmu.edu/~javabayes/Home/)  
[http:// \[www.mrc-bsu.cam.ac.uk/bugs/Welcome.html\]\(http://www.mrc-bsu.cam.ac.uk/bugs/Welcome.html\)](http://www.mrc-bsu.cam.ac.uk/bugs/Welcome.html)  
<http://www2.sis.pitt.edu/~genie>

[http:// \[www.hugin.dk\]\(http://www.hugin.dk\)](http://www.hugin.dk)  
[http:// \[www.kic.com/\]\(http://www.kic.com/\)](http://www.kic.com/)  
[http:// \[www.norsys.com/netica.html\]\(http://www.norsys.com/netica.html\)](http://www.norsys.com/netica.html)

## ANEXO 2 - ENTROPIA

Neste anexo aborda-se o conceito de entropia adotado no desenvolvimento de sistemas especialistas probabilísticos.

Entropia é uma medida da variedade observacional ou da diversidade atual (de forma oposta a possibilidade lógica). Diferente da medida de informação seletiva, a entropia considera que mensagens ou categorias de eventos podem ocorrer com igual frequência ou probabilidade. Embora entropia e informação estejam relacionadas, ambas são distintas entre si.

$$L^2 = 2n \sum (p \log_e (p / \pi)) = 1,3863 n I$$

Onde  $L^2$  é a máxima Likelihood. E assintoticamente tende para o  $\chi^2$ .

Uma medida razoável de incerteza remanescente após uma classificação múltipla é a diferença entre a incerteza na amostra antes de alguma classificação e a incerteza média na perda da classificação. A medida resultante é chamada entropia.

$$H(A) = \log_2 (n) - \sum (n_a/n) \log_2 (n_a/n)$$

Esta medida de entropia quantifica a redução de  $n$  observações distintas em poucas categorias. A entropia pode ser vista como a quantidade média de informação necessária para classificar (predizer ou identificar) observações em categorias:

$$H(A) = - \sum_{a \in A} (n_a/n) \log_2 (n_a/n)$$

Substituindo a frequência relativa  $(n_a/n)$  por seu caso limite a probabilidade  $p_a$  obtém-se:

$$H(A) = - \sum_{a \in A} p_a \log_2 p_a$$

que é a definição mais conhecida de entropia e foi introduzida nesta forma por Shannon e Weaver em 1949.

Parte da definição de entropia, e uma razão para chamá-la de medida de variedade observacional, é que possibilidades não observadas não podem entrar na medida. A média é calculada somente para categorias de observações que ocorrem ao menos uma vez. Convencionou-se que:  $(0 \log_2 0 = 0)$ .

Algumas propriedades de entropia:

a) A entropia é zero ou positiva e limitada por

$$0 \leq H(A) \leq H_{\max}(A)$$

$$H_{\max}(A) = - \log_2 (\min [N_A, n])$$

onde  $N_A$  é o número de categorias da variável A e n é o tamanho da amostra.

A entropia é zero quando não existe variedade observacional. Isto é, todas as observações estão numa mesma categoria.

A entropia é máxima quando as  $N_A$  células são ocupadas pelo mesmo número de observações  $n_a = n/N_A$ , é o caso em que frequências e probabilidades são uniformemente distribuídas ou quando  $n_a = 1$ , isto é todas as observações são únicas. Desta forma, a quantidade de incerteza  $U(A)$  é uma condição limite para valores de entropia.

- b) A entropia não informa sobre a natureza das categorias envolvidas. Seus rótulos são permutáveis livremente. Somente o conjunto de frequências ou probabilidades interessa. Neste sentido, a entropia é dita de livre contexto (*content-free*).
- c) A entropia nada assume sobre a natureza da distribuição de frequência ou de probabilidade, assim ela é uma medida não paramétrica de variedade e totalmente geral neste aspecto.
- d) A entropia é média. Pode-se interpretar entropia como o número médio de decisões binárias feitas durante uma classificação. Por exemplo, a participação de 32 eventos mede 1,875 bits (Figura 1). A árvore de decisão recursivamente divide-se em igual parte, cada uma somando 1 bit. Porém após a primeira distinção, a segunda é feita somente na metade dos casos e assim contribui somente com 0,5 bits. A terceira distinção é feita somente em um quarto dos casos e assim contribui com 0,25 bits, e etc.

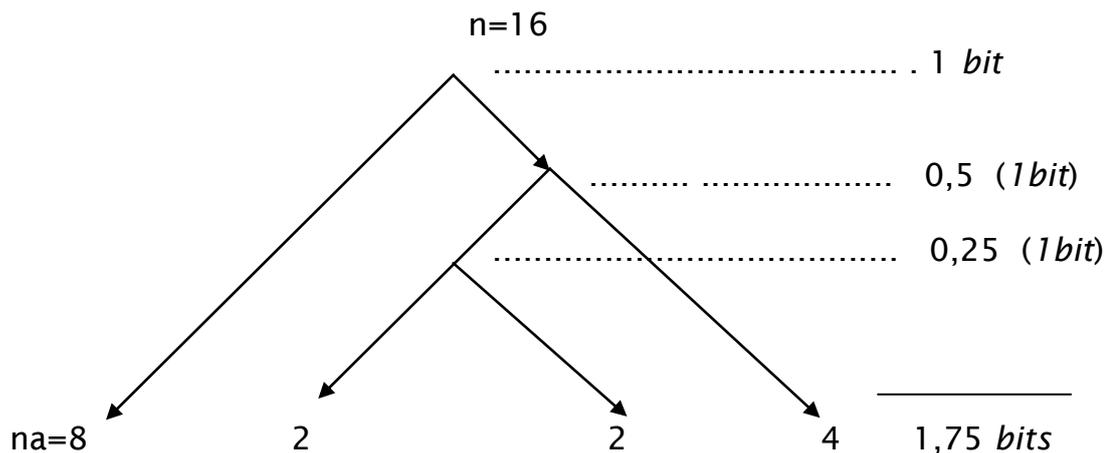


Figura 1- Ilustração de uma árvore binária de classificação de 16 eventos

- e) A entropia é uma função de magnitude relativa, sendo a probabilidade a forma mais comum. O tamanho da amostra não influencia os valores de entropia (exceto na forma de um viés estatístico). A padronização da entropia pode ser em relação ao seu valor máximo:

$$0 \leq H(A) / H_{\max}(A) \leq 1$$

A entropia padronizada expressa a magnitude da diversidade ou variedade (semelhante à variância), mas pode ser interpretada como um índice de uniformidade.

Medidas de entropia são uma fonte de dados para a construção de teorias onde a variedade, diversidade e diferenciação são o objetivo de generalização.

---

Krippendorff, K. Information Theory: structural models for qualitative data. London: SAGE Publications, 1986.

Shannon, C E & Weaver, W. A Teoria Matemática da Comunicação. São Paulo: DIFEL Difusão Editorial, 1975.

### **ANEXO 3 – Listas de Exercícios**

**UNIVERSIDADE FEDERAL DE SANTA CATARINA**  
**CENTRO TECNOLÓGICO**  
**DEPARTAMENTO DE INFORMÁTICA E DE ESTATÍSTICA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

Disciplina: Sistemas Especialistas Probabilísticos

Profa: Sílvia Modesto Nassar

**Exercícios de Probabilidade - Lista 1 – Calcular e, após, Modelar no NETICA**

1) Os dados da tabela abaixo descrevem o desempenho de alunos de graduação na disciplina de Probabilidade oferecida para alunos do Centro Tecnológico – UFSC.

Sexo	Aprovado	Reprovado	Total
Masculino	60	10	70
Feminino	30	0	30
Total	90	10	100

Considerando que será realizada a seleção aleatória de um estudante obtenha a probabilidade de ocorrência dos seguintes eventos:

- a) A: “O estudante é do sexo masculino”
- b) B: “O estudante foi aprovado”
- c) C: “O estudante é do sexo masculino e foi aprovado”
- d) E a probabilidade do evento: “O aluno é do sexo masculino ou foi aprovado” :

Torne a calcular a probabilidade dos eventos considerando agora que você tem as seguintes informações:

- e) D: “O estudante foi aprovado” , recalcule a probabilidade do item a.
- f) E: “O estudante selecionado é do sexo masculino” , recalcule a probabilidade do item b.

Na tabela acima estão descritos o Sexo e o Resultado obtido na disciplina, que conclusão você chega se tiver as seguintes informações:

- g) G: “O estudante foi reprovado”
- h) H: “O estudante é do sexo feminino”

Verifique se a condição de independência é satisfeita para os eventos A e B acima descritos.

2) Um certo meteorologista acerta 80% dos dias em que chove e 90% dos dias em que não chove. Em determinada região ocorre chuva em 10% dos dias. Considerando um dia qualquer obtenha a probabilidade dos seguintes eventos:

- a) A: “Há a previsão de chuva”.
- b) B: “Ocorrência de chuva” , se houve a previsão de chuva.
- c) C: “Ocorrência de chuva” , se houve a previsão de não chuva.

3) Em uma determinada região é feito o controle da qualidade da água por um bioquímico, que declarou que a água estará contaminada se houver a presença de "bacilos tipo A" e/ou "bacilos B e tipo C, simultaneamente". Informou ainda que em aproximadamente 30% das

análises encontrou bacilos tipo A, em 20% encontrou tipo B e em 50% bacilos tipo C. Por outro lado, sabe-se que existindo bacilos tipo A não existirão bacilos tipo B. Existindo bacilos tipo B reduz à metade a chance de ocorrência de bacilos C.

Obtenha a probabilidade de ocorrência dos seguintes eventos:

- a) "A água está contaminada".
- b) "Presença de bacilos tipo B na água" , considerando que você tem a informação que a água está contaminada.
- c) Considerando que você tem a informação de que há a presença de bacilos tipo B na água, recalcule a probabilidade do item a.

4) Duas máquinas M1 e M2 produzem o mesmo tipo de parafuso. A produção diária de cada uma dessas máquinas é 10000 e 15000 parafusos e a fração defeituosa é 0,5% e 1,0%, respectivamente. A produção diária é armazenada conjuntamente sem separação. Considerando que ao selecionar ao acaso um parafuso da produção total diária e procurando identificar os seguintes eventos:

Mi: "O parafuso foi produzido por Mi".

D: "O parafuso é defeituoso".

ND: "O parafuso é não defeituoso".

Resolva:

- a) Se o parafuso é defeituoso, qual a probabilidade dele ter vindo da máquina Mi?
- b) Se o parafuso é não defeituoso, qual a probabilidade dele ter vindo da máquina Mi ?

Verifique se a ocorrência do evento D é informação relevante para você tirar alguma conclusão sobre o evento Mi . E a ocorrência do evento ND é relevante para a ocorrência do evento Mi?

6) Você tem 90% de probabilidade de acertar esta questão e seu colega 80%. Considerando que sua solução independe da solução realizada por seu colega, resolva:

- a) calcule a probabilidade de que somente uma resposta esteja correta.
- b) faça uma RB com seguintes nodos:

Nodo 1 : representa o seu resultado.

Nodo 2: representa o resultado de seu colega.

Nodo 3: o numero total de questões com solução correta.

**UNIVERSIDADE FEDERAL DE SANTA CATARINA**  
**CENTRO TECNOLÓGICO**  
**DEPARTAMENTO DE INFORMÁTICA E DE ESTATÍSTICA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

Disciplina: Sistemas Especialistas Probabilísticos

Profa: Sílvia Modesto Nassar

**Exercícios de Probabilidade - Lista 2 - Calcular e, após, Modelar no NETICA**

1) Considere um sistema de alarme com dois detectores. Cada um deles pode ter algum dos componentes (evidências):

$e_1$  = (emite um som alto);  $e_2$  = (não emite som) e  $e_3$  = (emite um som baixo).

Considere a variável  $H = \{H_1, H_2, H_3, H_4\}$  definida pelas seguintes hipóteses:

$H_1$  = (não arrombamento, entrada de animal)

$H_2$  = (tentativa de arrombamento, janela quebrada)

$H_3$  = (tentativa de arrombamento, porta quebrada)

$H_4$  = (não arrombamento, nem entrada de animal)

As ligações entre as evidências e as hipóteses são dadas na tabela abaixo, onde os valores no corpo da tabela representam a probabilidade condicional  $P(e_j/H_i)$ :

Hipóteses	Evidências		
	$e_1$ = som alto	$e_2$ = não soa	$e_3$ = som baixo
$H_1$	0,10	0,50	0,40
$H_2$	0,44	0,06	0,50
$H_3$	0,40	0,50	0,10
$H_4$	0,00	1,00	0,00

Considere que o seguinte vetor de probabilidades a priori:

$(H_i) = (0,099 \ 0,009 \ 0,001 \ 0,891)$

Calcule a probabilidade de arrombamento sabendo que um detector emitiu um som alto ( $e_1$ ) e que o outro permaneceu em silêncio ( $e_2$ ), para as seguintes situações:

- a) as evidências foram observadas simultaneamente;
- b) primeiro observou-se  $e_1$  e após  $e_2$ ;
- c) primeiro observou-se  $e_2$  e após  $e_1$ ;
- d) calcule o vetor de probabilidades  $H_i$  para as entradas  $e_1$  e  $e_2$ .

**UNIVERSIDADE FEDERAL DE SANTA CATARINA**  
**CENTRO TECNOLÓGICO**  
**DEPARTAMENTO DE INFORMÁTICA E DE ESTATÍSTICA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

Disciplina: Sistemas Especialistas Probabilísticos

Profa: Sílvia Modesto Nassar

**Rede Bayesiana - Lista 3 - Calcular e, após, Modelar no NETICA**

1) Para o diagnóstico de Edemas Subcutâneos Generalizados, tais como Celulite e Alergia, são considerados os seguintes sintomas: Febre, Cor Local, Dor História de Alergia e Prurido.

A seguir são explicitadas as probabilidades a priori  $P(H_i)$  e as probabilidades condicionais  $P(e/H_i)$ .

Tabela 1 - Probabilidade de cada hipótese diagnóstica

Hipóteses Diagnósticas ( $H_i$ )	$P(H_i)$
<b>Celulite</b>	0,20
<b>Alergia</b>	0,80

Tabela 2 – Probabilidades condicionais de cada sintoma em relação às hipóteses diagnósticas

Evidências	$P(e_k/Celulite)$	$P(e_k/Alergia)$
<b>Febre</b>	Sim	0,85
	Não	0,15
<b>Cor Local</b>	Roxa	0,98
	Rósea	0,02
<b>Dor</b>	Leve	0,03
	Intensa	0,97
<b>História Alergia Família</b>	Sim	0,50
	Não	0,50
<b>Prurido</b>	Sim	0,50
	Não	0,50

Com os dados acima:

- Desenvolva uma Rede Bayesiana para Apoio ao Diagnóstico de Edemas Subcutâneos Localizados.
- Estabeleça um caso de consulta.
- Explicito o cálculo de algumas probabilidades da rede bayesiana.
- Cause ruídos de 5%, 10%, 15% e 20% enfraquecendo as probabilidades condicionais.
- Teste a RB original e as com ruído para o caso de consulta.

2) Para o diagnóstico da Dor de Cabeça nas seguintes intensidades: Forte, Média, Fraca ou Nenhuma, são considerados as seguintes entradas: Alimentação, Álcool, Estresse e Mudança Climática.

A seguir são explicitadas as probabilidades a priori  $P(H_i)$  e as probabilidades condicionais  $P(e/H_i)$ .

Tabela 1 - Probabilidade de cada hipótese diagnóstica

Hipóteses Diagnósticas ( $H_i$ )	$P(H_i)$
<b>Forte</b>	0,01000
<b>Média</b>	0,03333
<b>Fraca</b>	0,09000
<b>Nenhuma</b>	0,86667

Tabela 2 – Probabilidades condicionais de cada sintoma em relação as hipóteses diagnósticas

Evidências	$P(e_k/\text{Forte})$	$P(e_k/\text{Média})$	$P(e_k/\text{Fraca})$	$P(e_k/\text{Nenhuma})$
<b>Alimentação</b>				
Adequada	0,10	0,40	0,50	0,95
Indequerada	0,90	0,60	0,50	0,05
<b>Álcool</b>				
Sim	0,90	0,70	0,55	0,05
Não	0,10	0,30	0,45	0,95
<b>Estresse</b>				
Sim	0,20	0,70	0,80	0,50
Não	0,80	0,30	0,20	0,50
<b>Mudança climática</b>				
Sim	0,70	0,80	0,60	0,02
Não	0,30	0,20	0,40	0,98

Com os dados acima:

- Desenvolva uma Rede Bayesiana para Apoio ao Diagnóstico de Dor de Cabeça.
- Estabeleça um caso de consulta.
- Explicita o cálculo de algumas probabilidades da rede bayesiana.
- Cause ruídos de 5%, 10%, 15% e 20% enfraquecendo as probabilidades condicionais.
- Teste a RB original e as com ruído para o caso de consulta.