

Incerteza

- Bhatnagar (1986)
 - Incerteza
- Incerteza Tratada pela Matemática
 - Um evento particular dada determinadas observações

Regra de Bayes

- Probabilidades
 - Áreas de pesquisa
- Modelos Probabilísticos
- Teoria de Grafos
- Redes Bayesianas



IA – Origem e Contexto

- Uma máquina pensante e a curiosidade
 - Uniu duas áreas
- Divide-se em:
 - Sistemas Robótico
 - Sistemas Racionais


IA – Sistemas Racionais

- Raciocínio Lógico
 - Problema conhecido
- Raciocínio Probabilístico
 - Problema pouco ou nada conhecido


Redes Bayesianas

- Grafo orientado
- Nó = variável
- Arco = dependência probabilística

Redes Bayesianas



Redes Bayesianas



IA – Redes Bayesianas

- Informações com um CERTO nível de INCERTEZA

Raciocínio sobre Incerteza

- Impossibilidade de inserção de informações antecedentes
- Ignorância Teórica

Teorema de Bayes

•Definição:

- O modelo bayesiano interpreta a probabilidade de uma proposição como o grau de crença de um agente na veracidade dessa proposição.
- Exemplo: um dentista pode dizer: “na minha opinião, eu espero que a probabilidade de cárie seja aproximadamente 0.1”. $P(A|W)$ é o grau de crença do agente na veracidade da proposição A, dado sua experiência e conhecimento W.
- Nesse sentido, toda probabilidade é condicionada ao conhecimento do agente, diferentemente do enfoque em que se considera as probabilidades como sendo aspectos reais do universo não dependentes do conhecimento do agente

- **O teorema:**

- A inferência bayesiana repousa sobre o celebrado teorema de bayes, dado pela equação abaixo:

$$P(H \mid e) = \frac{P(e \mid H)P(H)}{P(e)}$$

Onde:

- $P(H)$ é a probabilidade de ocorrer H ;
- $P(H|e)$ é a probabilidade condicional de H , isto é, a probabilidade de H após conhecer a evidência e ;
- $P(e|H)$ é a probabilidade condicional de e , isto é, probabilidade de e após conhecer a evidência H ;
- Dado que $P(H|e) + P(\neg H|e) = 1$, tem-se que:
$$P(e|H)P(H) + P(e|\neg H)P(\neg H) = P(e).$$
- Deste modo, pode-se expressar a fórmula da inversão em termos proporcionais, sem o fator de normalização $P(e)$, como na equação abaixo:

$$P(H|e) = \alpha P(e|H)P(H)$$

Aplicações do Teorema de Bayes

- O teorema de bayes é amplamente utilizado na prática, pois existem muitos casos em que fazemos boas estimativas probabilísticas. Para sua aplicação, requer-se:
 - Conhecer as probabilidades *a priori* $p(\text{decisão})$;
 - As probabilidades condicionais $p(x|\text{decisão})$;

- **Exemplo 1**

- Determine se um paciente tem cancro (h_1) ou não (h_2), sabendo que o paciente foi submetido a um exame de laboratório para detectar se tinha cancro, e o resultado do exame deu positivo. Este exame devolve um resultado positivo (+) correto em 98% dos casos em que a doença está efetivamente presente, e um resultado negativo (-) correto em 97% dos casos em que a doença não está presente. Além disso, 0.008 da população total sofre de cancro.

• Exemplo 1 – Resolução

Probabilidade de ocorrer o evento	Evento
$P(+ h1) = 0.98$	Probabilidade do resultado do exame ser correto, dado que o paciente possui cancro.
$P(- h1) = 0.02$	Probabilidade do resultado do exame ser incorreto, dado que o do paciente possui cancro.
$P(h1)=0.008$	Probabilidade de a população sofrer de cancro
$P(- h2) = 0.97$	Probabilidade do resultado do exame ser correto, dado que o paciente não possui cancro.
$P(+ h2) = 0.03$	Probabilidade do resultado do exame ser incorreto, dado que o do paciente não possui cancro.
$P(h2)=1-P(h1) = 0.992$	Probabilidade da população não possuir cancro.

• Exemplo 1 – Resolução

- Para um novo doente onde o teste é positivo. Qual deverá ser o diagnóstico?

$$P(h1 | +) = ?$$

$$P(h2 | +) = ?$$

Como:

$$P(h1 | +) = \frac{P(+ | h1) \cdot P(h1)}{P(+)} = \frac{X}{K} \rightarrow P(h1|+) = P(+|h1) P(h1)$$

$$P(h2 | +) = \frac{P(+ | h2) \cdot P(h2)}{P(+)} = \frac{Y}{K} \rightarrow P(h2|+) = P(+|h2) P(h2)$$

Então, a hipótese resume-se a:

$$P(h1 | +) = (+ | h1) \cdot P(h1) \rightarrow (0,98) \times (0,008) = 0,00784$$

$$P(h2 | +) = P(+ | h2) \cdot P(h2) \rightarrow (0,03) \times (0,992) = 0,029$$

Logo, o doente não sofre de cancro, pois $H_{\text{máx}} = h2$

• Exemplo 2

- Pacientes com problemas cardíacos são sujeitos a um eletrocardiograma (ECG). Os resultados são classificados:
 - positivos (+ECG) sugerindo doença cardíaca (+DC)
 - negativos (-ECG) no caso de não haver doença cardíaca (-DC)

Assumindo que um dado paciente realizou um eletrocardiograma positivo pretende-se saber qual a probabilidade deste paciente ter doença cardíaca ? $\rightarrow P(+DC \mid + ECD)$

- **Exemplo 2 – Continuação**

- Sabendo que:
 - 10 pessoas em 100 têm um ataque cardíaco
 - 90 pessoas em 100 que tiveram doença cardíaca produziram um eletrocardiograma positivo
 - 95 pessoas em 100 que não tiveram doença cardíaca produziram um eletrocardiograma negativo

• Exemplo 2 - Resolução

- 10 pessoas em 100 têm um ataque cardíaco

$$\rightarrow P(+DC) = 0.1$$

$$\rightarrow P(-DC) = 1 - P(+DC) = 1 - 0.1 = 0.9$$

- 90 pessoas em 100 que tiveram doença cardíaca produziram um eletrocardiograma positivo (+ECD)

$$\rightarrow P(+ECD \mid +DC) = 0.9$$

- 95 pessoas em 100 que não tiveram doença cardíaca produziram um eletrocardiograma negativo (-ECD)

$$\rightarrow P(-ECD \mid -DC) = 0.95$$

$$\rightarrow P(+ECD \mid -DC) = 1 - P(-ECD \mid -DC) = 1 - 0.95 = 0.05$$

•Exemplo 2 - Resolução

- $P(+ECD) = P(+ECD|+DC) * P(+DC) + P(+ECD|-DC) * P(-DC)$
 $= 0.9 * 0.1 + 0.05 * 0.9 = 0,135$
- $P(+DC | + ECD) = (P(+ECD | +DC) * P(+DC)) / P(+ECD)$
- $P(+DC | + ECD) = 0.1 * 0.9 / 0,135 = 0.67 \rightarrow 67\%$

Logo a probabilidade do paciente ter doença cardíaca, sabendo que seu exame foi positivo é de 67%.

• Exemplo 3

- Um médico sabe que a meningite faz o paciente ter uma rigidez no pescoço, durante 50% do tempo. O médico também conhece alguns fatos incondicionais: a probabilidade *a priori* de um paciente ter meningite é $1/50.000$, e a probabilidade *a priori* de qualquer paciente ter uma rigidez no pescoço é $1/20$. Sendo s a proposição de que o paciente tem uma rigidez no pescoço e m a proposição de que o paciente tem meningite, temos:

• Exemplo 3 - Resolução

- $P(s|m) = 0,5$
- $P(m) = 1/50.000$
- $P(s) = 1/20$

- $$P(m/s) = \frac{P(s | m)P(m)}{P(s)} = \frac{0,5 * 1 / 50.000}{1 / 20} = 0,0002 =$$

$$0.02\% = 1 \text{ a cada } 5.000$$

• Exemplo 3 - Resolução

- Ou seja, esperamos que apenas 1 em 5.000 pacientes com rigidez no pescoço tenha meningite. Embora a rigidez no pescoço seja uma indicação bastante forte de meningite (com probabilidade 0,5), a probabilidade de o paciente estar acometido de meningite permanece pequena. Isso ocorre porque a probabilidade *a priori* sobre rigidez no pescoço é muito mais alta que a probabilidade *a priori* sobre a meningite.

Redes de Bayes

Redes de Bayes

Também conhecida como:

rede de crença bayesiana

ou diagrama de influência probabilística

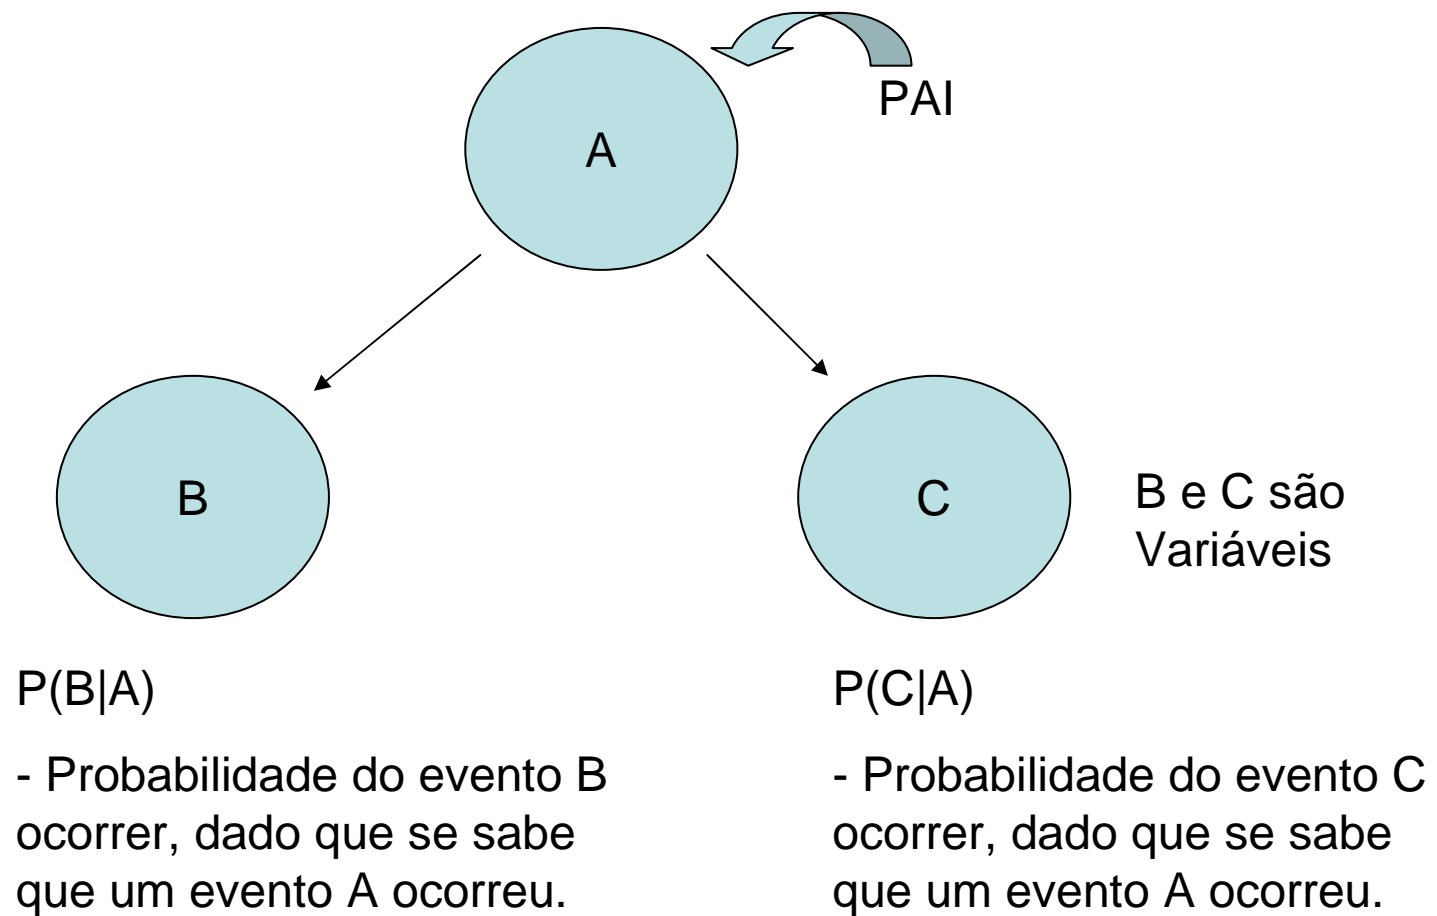
Características

- Expressam variáveis do problema e suas dependências;
- As dependências entre os itens (variáveis) serão expressas por probabilidades condicionais (do tipo $P(A|B)$).
- Do ponto de vista de um especialista, redes bayesianas constituem um modelo gráfico que representa de forma simples as relações das variáveis de um sistema.

Consistem em:

- Um conjunto de variáveis e um conjunto de arcos ligando as variáveis.
- Cada variável possui um conjunto limitado de estados mutuamente exclusivos.
- As variáveis e arcos formam um grafo dirigido sem ciclos.
- Para cada variável A que possui como pais B_1, \dots, B_n , existe uma tabela $P(A | B_1, \dots, B_n)$.


Ilustração



Demonstra as probabilidades condicionais

Ilustração

- Caso A não possua um pai, a tabela de probabilidades é reduzida para uma probabilidade incondicional $P(A)$.



Componentes de uma rede bayesiana

Possuem 2 componentes principais:

- uma estrutura, S , que define relacionamento entre os nós;
- parâmetros numéricos, Θ , que quantificam a relação probabilística causal entre os nós da estrutura.

Construindo Redes Bayesianas

- Escolher o conjunto das variáveis relevantes que descrevem o domínio do problema;
- Escolher uma ordem para as variáveis (os pais devem surgir antes dos nós);
- Para cada variável (chamada de X_i):
 - Escolher o conjunto de nós pais para a variável X_i , de modo a que este conjunto seja mínimo e que :
 $P(X_i \mid \text{Pais}(X_i))$
 - Definir a tabela de probabilidades condicionada para X_i .

Vantagens de uma Rede Bayesiana

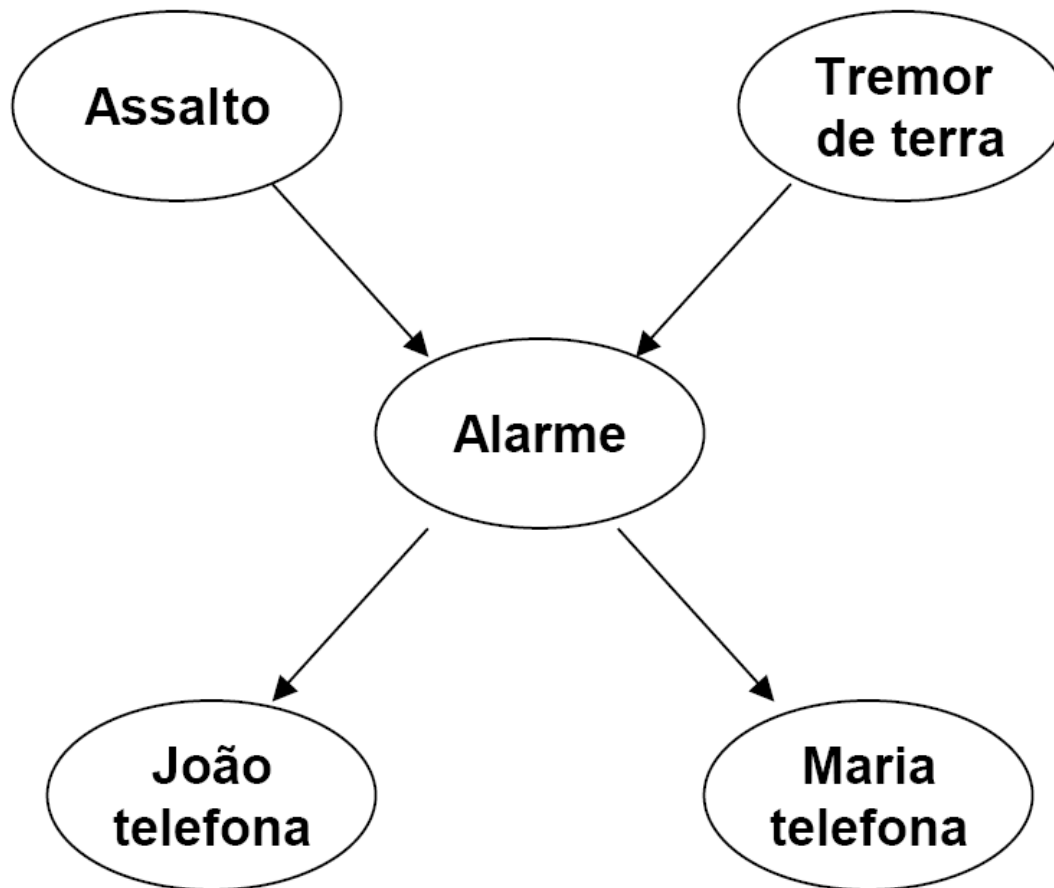
- Possuem grande campo de aplicações;
- As redes bayesianas oferecem uma estrutura unificada e intuitiva, onde é possível comparar diferentes hipóteses;
- Gráficos tornam fácil a compreensão do modelo, mesmo para usuários pouco familiarizados com a teoria Bayesiana;

Há várias outras vantagens, porém dependem do domínio do problema.

Exemplo 1 – Alarme

Você possui um novo alarme contra ladrões em casa. Este alarme é muito confiável na detecção de ladrões, entretanto, ele também pode disparar caso ocorra um terremoto. Você tem dois vizinhos, João e Maria, os quais prometeram telefonar-lhe no trabalho caso o alarme dispare. João sempre liga quando ouve o alarme, entretanto, algumas vezes confunde o alarme com o telefone e também liga nestes casos. Maria, por outro lado, gosta de ouvir música alta e às vezes não escuta o alarme. Este domínio pode ser representado de acordo com a figura seguinte.

Exemplo 1 – Alarme



Para que o alarme dispare, é necessário que haja um assalto ou tremor de terra...

Para que o João ou Maria telefone, é preciso que o alarma tenha disparado...

Exemplo 1 – Alarme

Lembre-se:

- Maria gosta de música alta; nem sempre pode ouvir o alarme!!
- João confunde o alarme com o telefone!!

Logo, a probabilidade que avisem ao escutar o alarme:

$P(\text{Alarme}, \text{João})$ e $P(\text{Alarme}, \text{Maria})$

Não são 1 !!

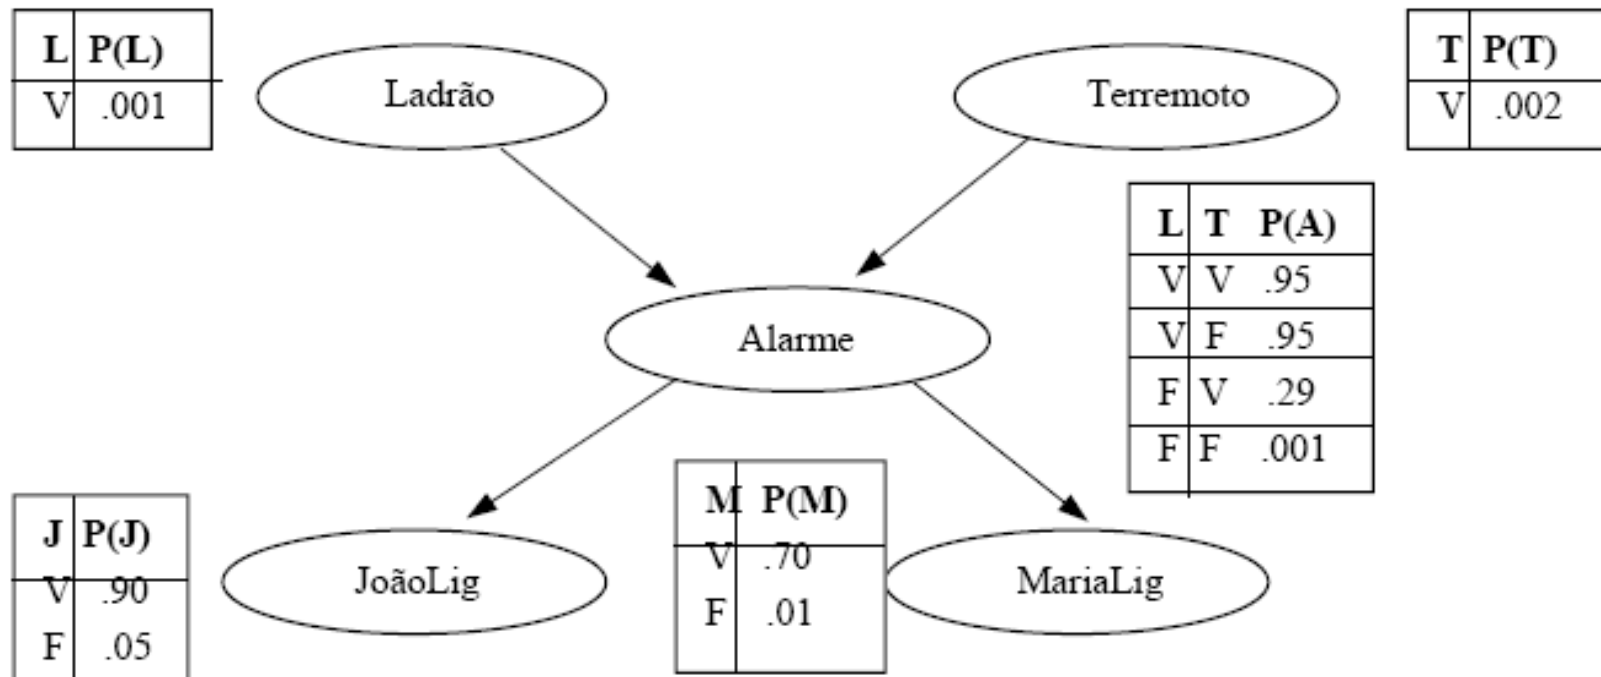
Exemplo 1 – Alarme

- Uma vez definido a topologia, é necessário se definir a tabela de probabilidades condicionais;
- Cada linha contém a probabilidade condicional para cada caso condicional dos nós pais;
- Um caso condicional é uma possível combinação dos valores para os nós pais.

Exemplo 1 – Alarme

Ladrão	Terremoto	$P(\text{Alarme} \text{Ladrão}, \text{Terremoto})$	
		Verdadeiro	Falso
Verdadeiro	Verdadeiro	0.95	0.050
Verdadeiro	Falso	0.95	0.050
Falso	Verdadeiro	0.29	0.71
Falso	Falso	0.001	0.999

Exemplo 1 – Alarme



Exemplo 1 – Alarme

- Diante disso tudo, pergunta-se: Qual a probabilidade do alarme ter tocado, mas, nem um ladrão nem um terremoto aconteceram, e ambos, João e Maria ligaram??

$$P(J \wedge M \wedge A \wedge \neg L \wedge \neg T).$$

Exemplo 1 – Alarme

$$P(J \wedge M \wedge A \wedge \neg L \wedge \neg T) =$$

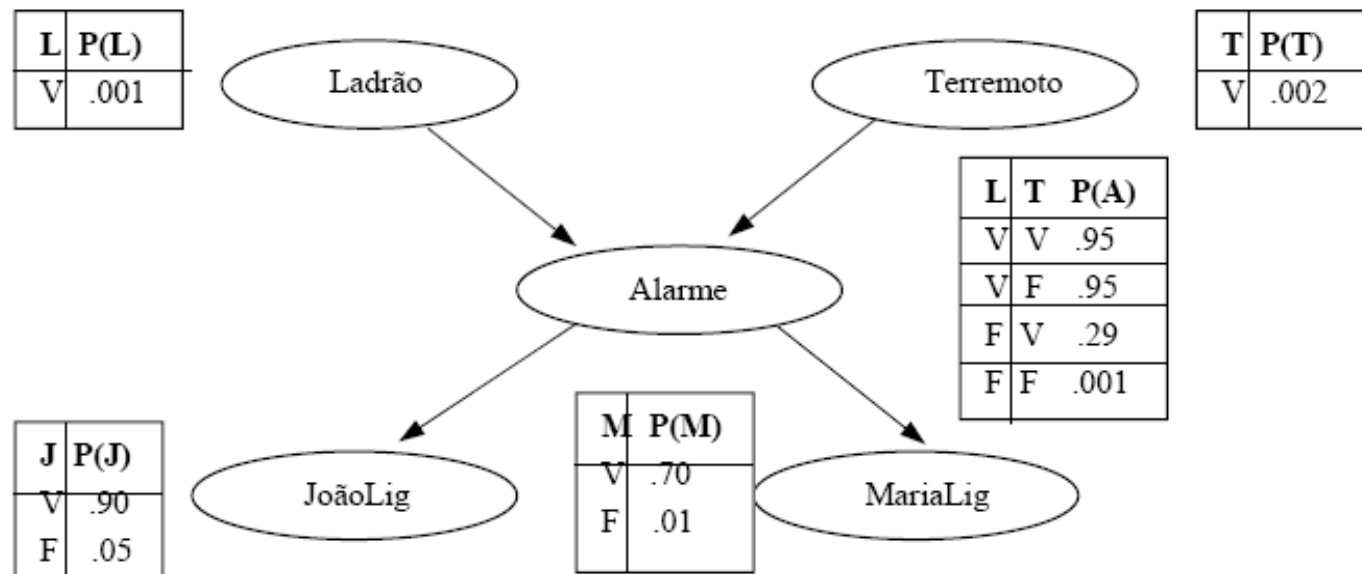
$$P(J|A) \times P(M|A) \times P(A|\neg L \wedge \neg T) \times P(\neg L) \times P(\neg T) =$$

$$0.9 \times 0.7 \times 0.001 \times 0.999 \times 0.998 =$$

$$0.00062$$

$$P(\neg L) = 1 - P(L)$$

$$P(\neg T) = 1 - P(T)$$



Exemplo 2 – Sistema Especialista

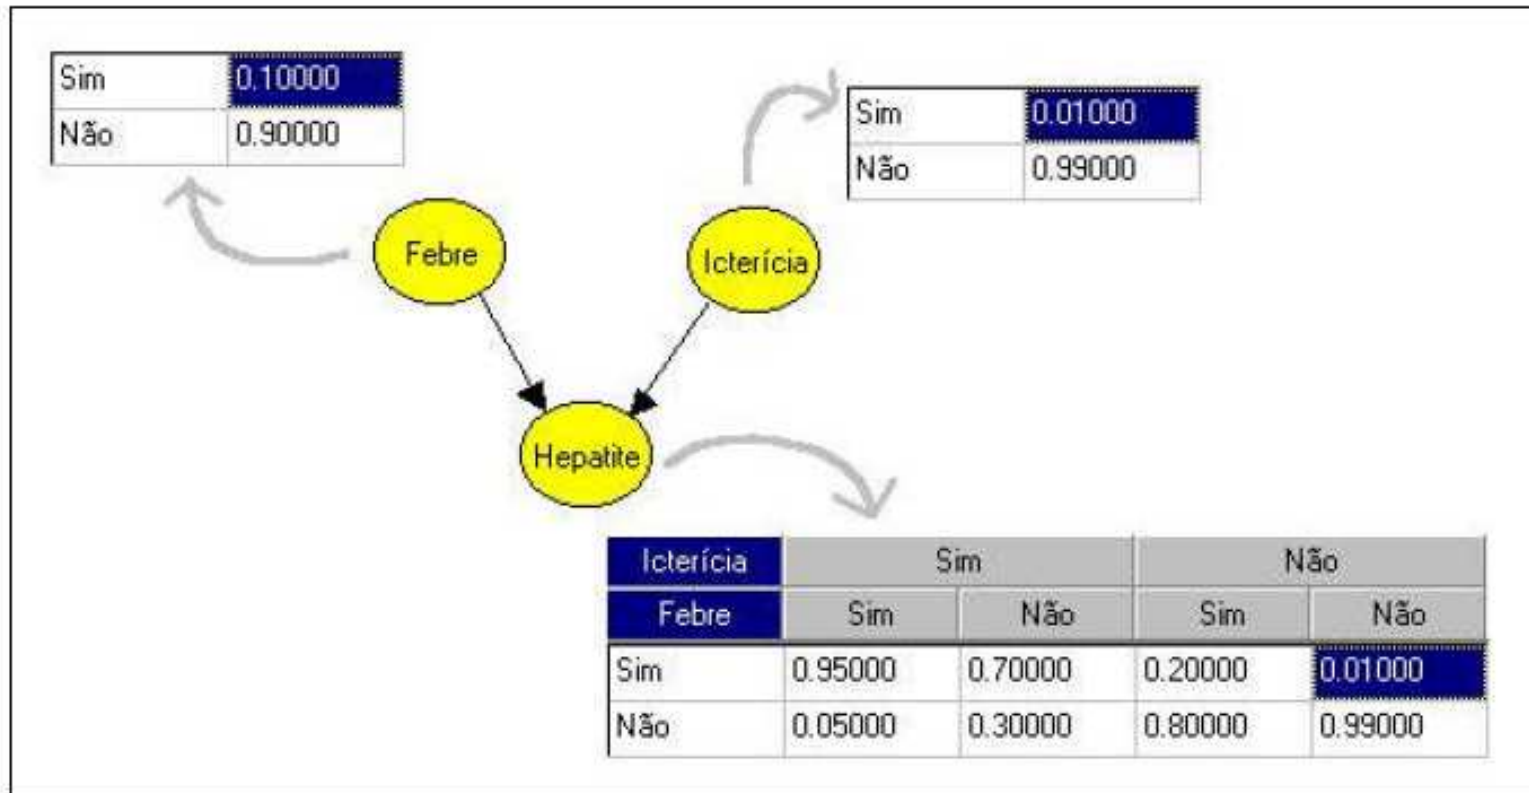
Nesse exemplo, podemos observar um domínio simples modelado a partir de uma Rede Bayesiana. Trata-se de um Diagnóstico da Hepatite. Possui três variáveis: *Febre*, *Icterícia* e *Hepatite*. Observe-se que as variáveis *Febre* e *Icterícia* estão associadas a tabelas de estados que indicam suas probabilidades a priori. As probabilidades a priori são o elemento responsável pelo tratamento da indeterminação. Quando o usuário não disser, ou não souber dizer o valor de uma evidência, a Rede Bayesiana usará, na inferência, essa probabilidade a priori, que foi definida pelo especialista como uma espécie de “valor padrão”.

Exemplo 2 – Sistema Especialista

- Variáveis: *Febre, Icterícia e Hepatite;*
- *febre e icterícia tem influência definida sobre hepatite;*

O valor das variáveis vão ser definidos conforme o valor das evidências.

Exemplo 2 – Sistema Especialista



O especialista, durante a modelagem da rede, indicará, para cada combinação de respostas das evidências relacionadas a esse diagnóstico, um valor de resultado. A inferência que ocorre na rede durante uma consulta se dá, então, por algoritmos multiplicativos, que vão propagando as probabilidades e definindo os valores finais dos diagnósticos.

Exemplo 3 – Anti-SPAM

O que é SPAM?

- “Email comercial não solicitado”
- “**Não é** email comercial não solicitado”
- “Email não solicitado enviado automaticamente”

Exemplo 3 – Anti-SPAM

- **O que há de especial no problema?**
- SPAM incomoda as pessoas;
- pode ser facilmente identificado por seres humanos, mas computadores têm dificuldade para tratar o problema;
- em geral métodos tradicionais conseguem filtrar spams, mas apresentam um alto índice de erros;
- os SPAMERS se adaptam ao longo do tempo para burlar os filtros;

Exemplo 3 – Anti-SPAM

```
<br>
Ge<!--##email##-->ne<!--sMSe-->ric Vi<!--sMSe-->ag<!--sMSe-->ra is now av<!--sMSe-->ail<!--sMSe-->able to co<!--sMSe-->nsu<!--sMSe-->me<!--sMSe-->rs<br> As
l<!--sMSe-->ow a<!--sMSe-->s $2.<!--sMSe-->25 per do<!--sMSe-->se (5<!--sMSe--><!--sMSe-->0 mg)<br> No Do<!--sMSe-->c
t<!--sMSe-->or's Co<!--sMSe-->nsu<!--sMSe-->lta<!--sMSe-->tion required<br>"S<!--sMSe-->il<!--sMSe-->agra is as go<!--sMSe-->od as V<!--sMSe-->i<!--sMSe-->a
g<!--sMSe-->ra - ju<!--sMSe-->st ch<!--sMSe-->ea<!--sMSe-->per!"<br>
<br>
```

Exemplo de SPAM html “adaptado”

Exemplo 3 – Anti-SPAM

- **tradução**

Generic Viagra is now
available to
consumers


As low as \$2.5 per dose (50 mg)

No Doctor's
Consultation required

"Silagra is as good as
Viagra - just
cheaper!"

Exemplo 3 – Anti-SPAM

A detecção de SPAM, portanto passa a ser um caso típico de detecção de padrões, um problema que pode ser atacado por técnicas de Inteligência Artificial, utilizando-se de Redes Bayesianas.



Pode-se observar que o nodo "C" é o nodo que serve como variável de classificação. As folhas da árvore são independentes entre si, e representam as variáveis representativas e importantes para o mecanismo de classificação.

Exemplo 3 – Anti-SPAM



Nas folhas, foram inseridos nodos de palavras “boas” e “ruins” com probabilidades associadas. Quando uma mensagem é submetida ao mecanismo, as palavras (ou *tokens*) são registrados como evidências, e para isto as variáveis (representadas nas folhas) são marcadas como “possui” e “npossui” conforme a mensagem. A entrada destas evidências fazem com que ocorra uma propagação das probabilidades, que influencia a distribuição de probabilidades no nodo “pai” responsável final pela classificação.

Exemplo 3 – Anti-SPAM

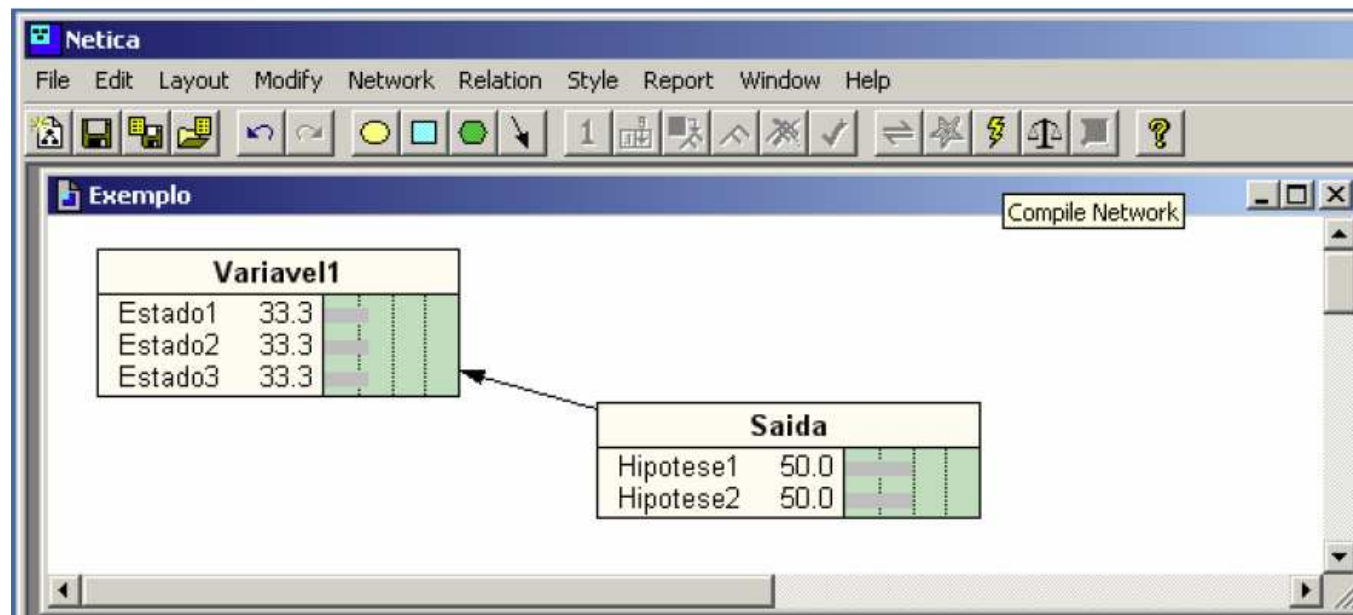
Diante desse modelo, foi implementado um sistema chamado BogoFilter, um software livre que nos mostrou características bastante importantes e desejáveis para identificar os padrões de SPAM, apresentando baixos índices de erros e altos índices de acerto em mensagens classificadas como SPAM.

Outras aplicações

- Extração de Conhecimento de Bases de Dados ;
- Aplicações Industriais;
- Apoio ao Diagnóstico Médico;
- Previsão de vendas;
- Dentre outros....

Ferramentas

Software NETICA



Hugin Expert

