

# *Probabilistic Knowledge Representation*

## Raciocínio Probabilístico

- Exemplo simples: diagnósticos.
- Para odontologia:

$$\forall p \text{ Sintoma}(p, \text{DorDeDente}) \Rightarrow \text{Enfermidade}(p, \text{Carie})$$

→ regra correta?

- Alternativa:

$$\forall p \text{ Sintoma}(p, \text{DorDeDente}) \Rightarrow \text{Enfermidade}(p, \text{Carie}) \vee \text{Enfermidade}(p, \text{Gengivite}) \vee \text{Enfermidade}(p, \text{SisoIncluso}) \dots$$

- Disjunção pode ser ilimitada.
- Outra alternativa, regra causal:

$$\forall p \text{ Enfermidade}(p, \text{Carie}) \Rightarrow (p, \text{DorDeDente})$$

→ regra correta?

- Conclusão: cáries e dores de dentes não estão necessariamente relacionados.

## Lidando com Incerteza

- Como representar alguma relação? Graus de incerteza ou de credibilidade (*degrees of belief* ou *degrees of truth*).
- Lógica de primeira ordem não consegue representar incerteza.
- 3 razões:
  - ▶ **Laziness**: muito trabalhoso codificar listas completas de antecedentes ou consequentes necessários para representar todas as regras, e muito ineficiente utilizar o conjunto enorme de regras.
  - ▶ **Ignorância teórica**: por exemplo, a ciência médica não tem uma teoria completa sobre o domínio.
  - ▶ **Ignorância prática**: mesmo sabendo todas as regras, pode aparecer um paciente com dados novos q não estavam previstos.

## Lidando com Incerteza

- Para lidar com incerteza: teoria das probabilidades: degree of belief, lógica fuzzy: degree of truth.
- Probabilidade fornece uma forma de resumir a incerteza proveniente de 'laziness' e ignorância.
- Por ex., *80% de pacientes já tratados que têm dor de dente, têm cárie.*
- 80% compreende todos os casos em que reunimos todas as condições necessárias para concluir que se um paciente tem dor de dente, também tem cárie, e todos os casos em que o paciente tem dor de dente e cárie, mas os dois não estão relacionados.

## Lidando com Incerteza

- 20% compreende todas as possíveis causas de dor de dente não relacionadas por laziness ou ignorância.
- $\text{Prob} = 0$ , sentença é categoricamente falsa.
- $\text{Prob} = 1$ , sentença é categoricamente verdadeira.
- **evidência**: utilizada pelo agente para atribuir novas probabilidades às proposições a partir de percepções do mundo.
- **probabilidade incondicional**: inicial (prior).
- **probabilidade condicional**: posterior, após evidências serem obtidas.

## Incerteza e Decisões Racionais

- Saída para o aeroporto.
- $A_{90}$  ou  $A_{120}$  ou  $A_{1440}$ ? O q é mais racional?
- Depende dos objetivos e do tempo q uma pessoa está preparada ou disposta a esperar pelo vôo no aeroporto.
- **Preferências** diferentes para as saídas do plano.
- Pe, Uma saída de um plano pode conter fatores tais como “agente vai chegar a tempo”, e “tempo de espera no aeroporto”.
- *Utility theory*: para atribuir graus de “utilidade” de um determinado estado.

# Agente baseado em Teoria da Decisão

- **Teoria da Decisão** = teoria das probabilidades + Teoria da Utilidade.
- Idéia fundamental: agente é racional sss escolher uma ação que produza o caminho mais útil, em relação a todos os possíveis resultados da ação (princípio MEU, Maximum Expected Utility).
- Agente baseado em teoria da decisão: estrutura similar a de um agente lógico.
- Linguagem para representação: lógica proposicional com probabilidades. Diferença sintática entre probabilidade incondicional e condicional (como em probabilidade).

## Revisão Probabilidade

- Probabilidade incondicional:  $P(A)$ , probabilidade incondicional de que proposição  $A$  é verdadeira.
- Pe,  $P(\text{Cárie}) = 0.1$ , 10% de chance de que o paciente tem cárie, **na ausência de qq outra informação**.
- Variáveis aleatórias (ref. prob.):
  - ▶  $P(\text{Tempo}=\text{Ensolarado}) = 0.7$
  - ▶  $P(\text{Tempo}=\text{Nublado}) = 0.08$
- Domínio: possíveis valores  $\langle x_1, x_2, \dots, x_n \rangle$  de uma variável aleatória (conjunto discreto para os exemplos mostrados).
- Convenção:  $A, B, \dots$  para variáveis booleanas.  $X, Y, \dots$  para variáveis com vários valores.
- $\mathbf{P}(\text{Tempo}) = (0.7, 0.2, 0.08, 0.02)$ : distribuição de probabilidade para a variável Tempo.



# Revisão Probabilidade

- $P(A|B)$ : probabilidade condicional.
- Pe,  $P(\text{Carie}|\text{DorDeDente}) = 0.8$ : chance de 80% do paciente ter cárie, dado que **tudo que sabemos até o momento** é que ele tem dor de dente.
- $P(A | B) = \frac{P(A \wedge B)}{P(B)}$ , com  $P(B) > 0$ .
- Regra do produto:  $P(A \wedge B) = P(A | B)P(B)$
- $\mathbf{P(X,Y) = P(X|Y)P(Y)}$
- Nem sempre evidência está disponível na base de dados: **inferência probabilística.**

## Axiomas da Probabilidade

- $0 \leq P(A) \leq 1$
- $P(\text{True}) = 1, P(\text{False}) = 0$
- $P(A \vee B) = P(A) + P(B) - P(A \wedge B)$  (ref. diag Venn).

- Propriedades:

$$P(A \vee \neg A) = P(A) + P(\neg A) - P(A \wedge \neg A)$$

$$P(\text{True}) = P(A) + P(\neg A) - P(\text{False})$$

$$1 = P(A) + P(\neg A)$$

$$p(\neg A) = 1 - P(A)$$

- de Finetti: Crenças inconsistentes levam agente sempre a perder ou produzir ações não desejadas. Axiomas são importantes, pq não deixam agentes criarem inconsistências.

# Distribuição de Probabilidade Conjunta

- $\mathbf{P}(X_1, \dots, X_n)$ : atribui probabilidades a todos os possíveis *eventos atômicos*.
- *Evento Atômico*: atribuição de valores particulares para todas as variáveis, especificação completa do domínio.

	DorDeDente	$\neg$ DorDeDente
• Pe: Carie	0.04	0.06
$\neg$ Carie	0.01	0.89

# Utilização de Distribuição de Probabilidade Conjunta

- $P(\text{Carie}): 0.06 + 0.04 = 0.10$
- $P(\text{Carie} \vee \text{DorDeDente}) = 0.04 + 0.01 + 0.06 = 0.11$
- Mecanismo de inferência pode encontrar probabilidades de uma proposição A, dada a evidência B.
- $P(\text{Carie} | \text{DorDeDente}) = \frac{0.04}{0.04+0.01} = 0.80$
- Em problemas reais, não é aconselhável usar distribuição de probabilidade conjunta: não prático armazenar a tabela com  $2^n$  entradas para n variáveis booleanas.
- sistemas de raciocínio modernos: lidam diretamente com probabilidades condicionais.

## Regra de Bayes

- $P(B | A) = \frac{P(A|B)P(B)}{P(A)}$ : teorema, lei ou regra de Bayes.
- Fundamenta a maior parte dos sistemas probabilísticos de inferência.
- Forma geral:

$$P(Y | X) = \frac{P(X | Y).P(Y)}{P(X)}$$

- Na prática regra de Bayes é útil, porque na maioria dos problemas temos estimativas para as duas probabilidades incondicionais e para a probabilidade condicional.
- Pe, um médico sabe que meningite causa rigidez nos músculos do pescoço do paciente, em 50% dos casos.
- Tb sabe dois fatos incondicionais: a prob de um paciente ter meningite é  $\frac{1}{50.000}$ , e a prob de um paciente ter rigidez dos músculos do pescoço é  $\frac{1}{20}$ .

## Regra de Bayes

- S = paciente tem rigidez do pescoço, M = paciente tem meningite.

$$P(S | M) = 0.5$$

$$P(M) = \frac{1}{50.000}$$

$$P(S) = \frac{1}{20}$$

$$P(M | S) = \frac{P(S|M)P(M)}{P(S)} = \frac{0.5 \times \frac{1}{50.000}}{\frac{1}{20}} = 0.0002$$

- ie, somente 1 em cada 5000 pacientes com rigidez do pescoço têm meningite.

# Regra de Bayes

- conhecimento sobre diagnósticos é mais superficial do que conhecimento causal.
- se surgir uma epidemia de meningite,  $P(M)$  vai subir.
- um médico que não usa regra de Bayes não vai saber como atualizar seus dados puramente estatísticos. Um médico usando regra de Bayes sabe que  $P(M|S)$  cresce proporcionalmente com  $P(M)$ .

## Regra de Bayes: Normalização

- Considere novamente a equação para calcular a probabilidade de meningite dado rigidez do pescoço:

$$P(M | S) = \frac{P(S|M)P(M)}{P(S)}$$

- Considere a possibilidade do paciente ter rigidez do pescoço e isto causar uma distensão dos músculos:

$$P(W | S) = \frac{P(S|W)P(W)}{P(S)}$$

- **probabilidade relativa:**

$$P(S | W) = 0.8 \text{ e } P(W) = \frac{1}{1000}$$

$$\frac{P(M|S)}{P(W|S)} = \frac{P(S|M)P(M)}{P(S|W)P(W)} = \frac{1}{80}$$

- ie, distensão é 80 vezes mais frequente do que meningite, dado que o paciente tem rigidez dos músculos do pescoço.



## Regra de Bayes – Normalização

- Em alguns casos, probabilidades relativas são suficientes para tomar decisões, mas em outros casos, há necessidade de calcular valores mais precisos, sem precisar utilizar  $P(S)$  (probabilidade incondicional): **normalização**.

$$P(M | S) = \frac{P(S|M)P(M)}{P(S)}$$

$$P(\neg M | S) = \frac{P(S|\neg M)P(\neg M)}{P(S)}$$

Adicionando: (obs:  $P(M | S) + P(\neg M | S) = 1$ )

$$P(S) = P(S | M)P(M) + P(S | \neg M)P(\neg M)$$

- Substituindo na regra de Bayes:

$$P(M | S) = \frac{P(S|M)P(M)}{P(S|M)P(M) + P(S|\neg M)P(\neg M)}$$

- regra geral:  $\mathbf{P}(Y | X) = \alpha \mathbf{P}(X | Y) \mathbf{P}(Y)$

## Usando a Regra de Bayes: combinação de evidências

- Assuma:  
 $P(\text{Carie} \mid \text{DorDeDente}) = 0.8$   
 $P(\text{Carie} \mid \text{MotorPrendeu}) = 0.95$
- O que é que um(a) dentista pode concluir se o motor prendeu no dente em que o paciente sente dor?
- Usando tabela de distr. de prob. conjunta, bastaria consultar tabela para encontrar  
 $P(\text{Carie} \mid \text{DorDeDente} \wedge \text{MotorPrendeu})$ .
- Usando Bayes:

$$\begin{aligned}
 &P(\text{Carie} \mid \text{DorDeDente} \wedge \text{MotorPrendeu}) = \\
 &= \frac{P(\text{DorDeDente} \wedge \text{MotorPrendeu} \mid \text{Carie})P(\text{Carie})}{P(\text{DorDeDente} \wedge \text{MotorPrendeu})}
 \end{aligned}$$

## Usando a Regra de Bayes: combinação de evidências

- esta forma pode levar a um número exponencial de valores de probabilidade se tivermos conjunções com mais variáveis. Por que não voltar a usar tabela de prob. conjunta neste caso?
- A utilização pura de teoria das probabilidades leva a que, para alguns casos, tenhamos que fazer um número exponencial de cálculos. Neste caso, métodos aproximados para tratar combinações de evidências são utilizados.

## Usando a Regra de Bayes: combinação de evidências

- Em alguns domínios, Bayes pode ser simplificada e usar menos valores de probabilidades para produzir resultados: **atualização bayesiana** (*bayesian updating*).

$$\begin{aligned} P(\text{Carie} \mid \text{DorDeDente}) &= \\ &= P(\text{Carie}) \frac{P(\text{DorDeDente} \mid \text{Carie})}{P(\text{DorDeDente})} \end{aligned}$$

## Usando a Regra de Bayes: combinação de evidências

- qdo MotorPredeu é observado, aplicamos novamente Bayes com DorDeDente como variável condicional de contexto:

$$\begin{aligned} & P(\text{Carie} \mid \text{DorDeDente} \wedge \text{MotorPredeu}) = \\ & = P(\text{Carie} \mid \text{DorDeDente}) \frac{P(\text{MotorPredeu} \mid \text{DorDeDente} \wedge \text{Carie})}{P(\text{MotorPredeu} \mid \text{DorDeDente})} \end{aligned}$$

- Em atualização bayesiana, cada vez que uma nova evidência é observada, a crença é multiplicada por um fator que depende da nova evidência.

## Usando a Regra de Bayes: combinação de evidências

- Ainda está complicado!
- $P(\text{MotorPrendeu} \mid \text{DorDeDente} \wedge \text{Carie})$  não é mais fácil de ser calculado do que  $P(\text{DorDeDente} \wedge \text{MotorPrendeu} \mid \text{Carie})$ !
- observação chave: cárie é causa direta da dor de dente e do motor ter agarrado ao dente, neste exemplo.
- Simplificação: **independência condicional** de DorDeDente e de MotorPrendeu, dado Carie:

$$\begin{aligned} P(\text{MotorPrendeu} \mid \text{Carie} \wedge \text{DorDeDente}) &= P(\text{MotorPrendeu} \mid \text{Carie}) \\ P(\text{DorDeDente} \mid \text{Carie} \wedge \text{MotorPrendeu}) &= P(\text{DorDeDente} \mid \text{Carie}) \end{aligned}$$

- Simplificando:

$$\begin{aligned} &P(\text{Carie} \mid \text{DorDeDente} \wedge \text{MotorPrendeu}) = \\ &P(\text{Carie}) \frac{P(\text{DorDeDente} \mid \text{Carie})}{P(\text{DorDeDente})} \frac{P(\text{MotorPrendeu} \mid \text{DorDeDente} \wedge \text{Carie})}{P(\text{MotorPrendeu} \mid \text{DorDeDente})} \end{aligned}$$

# Sistemas de Raciocínio Probabilístico

- Como construir sistemas de raciocínio utilizando modelos de redes e que usem incerteza de acordo com a teoria das probabilidades?
- **Rede de Crença** ou rede bayesiana: grafo com as seguintes características:
  - ▶ Nós representam variáveis aleatórias.
  - ▶ Arcos direcionados representam ligações diretas entre variáveis aleatórias.
  - ▶ Cada nó tem uma tabela de prob. cond. que quantifica o efeito dos pais deste nó.
  - ▶ O grafo não possui ciclos (DAG).
- relativamente fácil para um especialista definir as relações do que definir as probs.

# Sistemas de Raciocínio Probabilístico


- Redes de Crença:
  - ▶ Representação do Conhecimento
    - modelo gráfico de representação baseado no grafo acíclico
  - ▶ Dada a rede e as TPC:
    - podemos fazer consultas (inferência probabilística: exata ou aproximada)
  - ▶ Dada a rede e dados:
    - podemos “aprender” as TPC (parâmetros)
  - ▶ Se não tivermos a rede e nem as TPC:
    - podemos “aprender” as TPC (parâmetros) e a estrutura da rede




# Sistemas de Raciocínio Probabilístico

- Exemplo: alarme contra roubo.
- Alarme toca em duas situações: tentativa de roubo e terremoto.
- John e Mary são os vizinhos que avisam ao dono da casa se o alarme estiver tocando.
- John liga toda vez q o alarme toca e tb qdo o tel toca.
- Mary somente liga qdo o alarme toca, mas não ouve algumas vezes.
- Dada a evidência de quem ligou para o dono da casa, queremos descobrir a probabilidade de ter havido roubo.

# Sistemas de Raciocínio Probabilístico



# Sistemas de Raciocínio Probabilístico



## Sistemas de Raciocínio Probabilístico

- Rede somente representa ligações diretas, causais.
- Nada é informado sobre Mary ouvir música alta ou de John confundir o tel com o alarme.
- Tabela de probabilidades condicionais:

Roubo	Ter.	$\mathbf{P}(\textit{Alarme} \mid \textit{Roubo}, \textit{Terr})$
T	T	0.950 0.050
T	F	0.950 0.050
F	T	0.290 0.710
F	F	0.001 0.999

# Semântica das Redes de Crenças

- Duas formas de entender:
  - ▶ representação da distribuição de probabilidade conjunta. Útil para **construir** redes.
  - ▶ conjunto de sentenças condicionalmente independentes. Útil para projetar procedimentos de inferência.
- Representando distribuição de probabilidade conjunta:
  - ▶ cada entrada na tabela pode ser calculada através da info na rede.
  - ▶ uma entrada genérica representa a probabilidade de uma conjunção de valores atribuídos a cada variável:

$$P(X_1 = x_1 \wedge \dots \wedge X_n = x_n).$$

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i \mid Pais(X_i))$$

# Inferência Probabilística

- Método de “Eliminação de variáveis” (**variable elimination**)
  - ▶ (aplicado ao exemplo Weather-Sprinkler-Lawn em aula teórico-prática)

# Tipos de Inferência Probabilística

- Belief updating:

$$Bel(X_i) = P(X_i = x_i \mid evidence)$$

- Most Probable Explanation (MPE):

$$\bar{x}^* = \arg \max_{\bar{x}} P(\bar{x}, e)$$


- Maximum A Posteriori hypothesis (MAP):

$$(a_1^*, \dots, a_k^*) = \arg \max_{\bar{x}} \sum_{X/A} P(\bar{x}, e)$$

- Maximum Expected Utility (MEU) decision:

$$(d_1^*, \dots, d_k^*) = \arg \max_{\bar{x}} \sum_{X/D} P(\bar{x}, e) U(\bar{x})$$

## Redes de Bayes





## Redes de Bayes

Calcular a probabilidade de ter havido um roubo dado que o alarme tocou.

$$P(B | A) = \frac{P(A | B) \times P(B)}{P(A)} =$$

$$= \frac{P(A | B, E) \times P(B, E) + P(A | B, \neg E) \times P(B, \neg E) + P(A | \neg B, E) \times P(\neg B, E) + P(A | \neg B, \neg E) \times P(\neg B, \neg E)}{P(A)}$$

# Construção das TPC

- dados completos: Maximum Likelihood (ML), MAP
- dados incompletos: Expectation Maximization
- quando faltam combinações de valores de variáveis: “imputação”
  - ▶ Maximum Likelihood
  - ▶ Laplace
  - ▶ m-estimate (precisa especificar um valor para m)

## Construção de Redes de Crenças

- cada entrada na tabela é representada pelo produto dos elementos apropriados das tabelas de probabilidades condicionais (TPCs).
- TPCs fornecem uma representação decomposta da distribuição conjunta.

- Exemplo:

$$\begin{aligned} P(J \wedge M \wedge A \wedge \neg B \wedge \neg E) &= \\ &= P(J | A)P(M | A)P(A | \neg B \wedge \neg E)P(\neg B)P(\neg E) = \\ &= 0.9 \times 0.7 \times 0.001 \times 0.999 \times 0.998 = 0.00062 \end{aligned}$$

- Métodos melhores do que obter a tabela inteira de distribuição de probabilidade conjunta.

# Construção de Redes de Crenças

- Método para construir redes de crenças:
  - ▶ Rede é construída de forma que cada nó é condicionalmente independente dos seus predecessores, dada a probabilidade dos seus pais.
  - ▶ equação  $P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i \mid Pais(x_i))$  usada para guiar o engenheiro de conhecimento a construir a topologia da rede.
  - ▶ Para construir uma rede de forma que esta tenha a estrutura correta para o domínio, escolhe-se nós pais adequados para garantir que cada nó é condicionalmente independente de seus antecessores.

## Construção de Redes de Crenças

- Em geral:

$\mathbf{P}(X_i | X_{i-1}, \dots, X_1) = P(X_i | Pais(X_i))$ , desde que  $Pais(X_i)$  seja subconjunto ou igual a  $\{x_{i-1}, \dots, x_1\}$

- Esta condição é alcançada desde que se rotule os nós da rede em qq ordem q seja consistente com a ordem parcial implícita na estrutura do grafo.
- Ex: Mary telefona: não é **diretamente** influenciado por tentativa de assalto ou terremoto. É influenciado pelo efeito de tentativa de assalto ou terremoto, ou seja, soar o alarme.
- o Fato de John telefonar tb não tem influência direta sobre o fato de Mary telefonar. Neste caso temos independência condicional:

$\mathbf{P}(MaryTel | JohnTel, Alarme, Terr, Assalto) = \mathbf{P}(MaryTel | Alarme)$

# Construção de Redes de Crenças

- Procedimento geral para construção de redes:
  1. Escolha o conj de variáveis  $X_i$  relevantes que descrevam o domínio.
  2. Escolha ordem para as variáveis.
  3. Eqto há vars:
    - a) Pegue uma var  $X_i$  e adicione um nó na rede para  $X_i$ .
    - b) Construir  $Pais(X_i)$  com um conj mínimo de nós que já estejam na rede, tal que a prop de indep cond seja satisfeita.
    - c) Defina a tabela de prob cond p/  $X_i$ .

# Construção de Redes de Crenças

- Procedimento garante que a rede é acíclica.
- Rede não contém valores de probabilidades redundantes.
- Garante que axiomas da prob não são violados.

## Example of belief network construction

- Assuming the order:  $M, J, A, B, E$




$$P(J \mid M) = P(J)?$$



## Example of belief network construction

- Assuming the order:  $M, J, A, B, E$




$P(J | M) = P(J)$ ? No

$P(A | J, M) = P(A | J)$ ?  $P(A | J, M) = p(A)$ ?

## Example of belief network construction

- Assuming the order:  $M, J, A, B, E$



$P(J | M) = P(J)$ ? No


$P(A | J, M) = P(A | J)$ ?  $P(A | J, M) = p(A)$ ? No

$P(B | A, J, M) = P(B | A)$ ?

$P(B | A, J, M) = P(B)$ ?

## Example of belief network construction

- Assuming the order:  $M, J, A, B, E$



$P(J | M) = P(J)$ ? No

$P(A | J, M) = P(A | J)$ ?  $P(A | J, M) = p(A)$ ? No

$P(B | A, J, M) = P(B | A)$ ? Yes

$P(B | A, J, M) = P(B)$ ? No

$P(E | B, A, J, M) = P(E | A)$ ?

$P(E | B, A, J, M) = P(E | A, B)$ ?

## Example of belief network construction

- Assuming the order:  $M, J, A, B, E$



$P(J | M) = P(J)$ ? No

$P(A | J, M) = P(A | J)$ ?  $P(A | J, M) = p(A)$ ? No

$P(B | A, J, M) = P(B | A)$ ? Yes

$P(B | A, J, M) = P(B)$ ? No

$P(E | B, A, J, M) = P(E | A)$ ? No

$P(E | B, A, J, M) = P(E | A, B)$ ? Yes

## Compactação e Ordenação de Nós

- Redes de crenças + **compactas** do que distribuição de prob conjunta.
- Sistemas **localmente estruturados** ou esparsos com info distribuída pelos nós.
- Crescimento polinomial.
- Em redes de crenças, podemos assumir que para a maioria dos domínios, cada variável aleatória é diretamente influenciada por no max k outras vars (nós pais).
- Qtde necessária de valores para a TPC de cada nó:  $2^k$ .
- Para a rede completa (n nós):  $n2^k$ .

## Compactação e Ordenação de Nós

- Ex concreto: rede com 20 nós e no max 5 pais p/ cada nó:
  - ▶ redes de crença: 640 valores.
  - ▶ tabela de distr de prob conj: ordem de  $10^6$  valores.
- Número de links extra na rede = maior precisão, mas pode não se justificar devido ao aumento do tamanho das tabelas.
- Regra geral: adicionar à rede primeiro os nós causadores de algum efeito e depois seus efeitos.

## Representação de TPCs

- Problema: escolher as probs condicionais das TPCs.
- Relação entre pais e filhos pode se encaixar numa distribuição canônica. Neste caso, probs podem ser especificadas através de nomes e talvez parms adicionais.
- Ex mais simples: nós determinísticos, probs são iguais às probs dos pais.
- Nós não determinísticos: relação *ruidosa* OU.
- Representação das probs:
  - ▶ Se todos os pais F, nó de saída F, com 100% de certeza.
  - ▶ Se apenas 1 dos pais é V, nó de saída é F com prob = parâmetro ruidoso daquele nó pai que é V.

## Representação de TPCs

- Ex:  $P(\text{Febre} \mid \text{Resf}) = 0.4$ ,  $P(\text{Febre} \mid \text{Gripe}) = 0.8$  e  $P(\text{Febre} \mid \text{Mal}) = 0.9$

Resf	Gripe	Mal	P(Febre)	P( $\neg$ Febre)
F	F	F	0.0	1.0
F	F	V	0.9	0.1
F	V	F	0.8	0.2
F	V	V	0.98	$0.02 = 0.2 \times 0.1$
V	F	F	0.4	0.6
V	F	V	0.94	$0.06 = 0.6 \times 0.1$
V	V	F	0.88	$0.12 = 0.6 \times 0.2$
V	V	V	0.988	$0.012 = 0.6 \times 0.2 \times 0.1$




## Relações de Independência Condicional

- Necessidade: saber se relações de independência condicional mais gerais (não somente de pais p/ filhos) existem para poder obter mecanismos de inferência capazes de responder consultas do tipo: “Existe algum conj de nós  $X$  independente de outro conj  $Y$ , dado conj de evidências  $E$ ?”
- Método: **direction-dependent separation** ou **d-separation** (separação-d).
- separação-d: *se todo ramo não dirigido de um nó em  $X$  para um nó em  $Y$  é d-separado por  $E$ , então  $X$  e  $Y$  são condicionalmente independentes, dado  $E$ .*
- Um conj de nós  $E$  d-separa dois conj  $X$  e  $Y$  se todo ramo não dirigido de um nó em  $X$  para um nó em  $Y$  estiver **bloqueado**, dado  $E$ .

# Relações de Independência Condicional

- Um ramo está bloqueado, dado um conj de nós  $E$ , se houver um nó  $Z$  no caminho tal que uma das três condições é satisfeita:
  1.  $Z$  está em  $E$  e  $Z$  tem um arco incidente e outro não incidente.
  2.  $Z$  está em  $E$  e  $Z$  tem ambos os arcos não incidentes.
  3. Nem  $Z$  nem nenhum descendente de  $Z$  estão em  $E$ , e ambos os arcos incidem em  $Z$ .

# Inferência em Redes de Crenças



# Inferência em Redes de Crenças

- Objetivo principal: computar distribuição de probabilidade posterior para um conj de variáveis de consulta, dados valores exatos para variáveis de evidência:  
 $P(Cons \mid Evidencia)$ .
- A princípio, qq nó pode servir como consulta ou evidência.
- Duas funções: BELIEF\_NET\_TELL p/ incluir novas evidências na rede e BELIEF\_NET\_ASK p/ computar novas probs p/ as variáveis de consulta.


## Inferência em Redes de Crenças

- **Diagnósticas:**  $P(\textit{Assalto} \mid \textit{JohnTel})$  (efeitos p/ as causas).
- **Causais:**  $P(\textit{JohnTel} \mid \textit{Assalto})$  (causas p/ os efeitos).
- **Inter-causais:**  $P(\textit{Assalto} \mid \textit{Alarme} \wedge \textit{Terr})$ .
- **Mistas:** combinação de 1 ou mais dos casos acima.
- Redes de crenças ainda podem ser usadas para:
  - ▶ tomar decisões baseadas em probs na rede e em funções de utilidade do agente.
  - ▶ decidir quais variáveis de evidência observar para obter info mais útil.
  - ▶ fazer “análise de sensibilidade” para entender aspectos do modelo que têm  $>$  impacto nas probs das vars de consulta.
  - ▶ Explicar os resultados da inferência probabilística para o utilizador.

# Inferência em Redes de Crenças

- Algoritmo BELIEF\_NET\_ASK análogo ao backward-chain, faz inferências a partir das variáveis de consulta até encontrar alguma evidência.
- Algoritmo funciona somente para redes “singly connected”, onde há no máximo um ramo não dirigido entre quaisquer dois nós da rede: **poli-árvores**.
- Algoritmos para redes mais gerais usam algoritmos poli-árvore como sub-rotinas.

# Inferência em Redes de Crenças



## Inferência em Redes de Crenças

- Nó  $X$  tem pais  $U$  e filhos  $Y$ .
- “singly connected” significa que todos os blocos são disjuntos e não têm links.
- $X$  é a variável de consulta.
- Objetivo: computar  $P(X | E)$ .
- Conjunto de **suporte causal**: variáveis de evidência “acima” de  $X$  que estão conectadas a  $X$  através dos pais.
- Conjunto de **suporte evidencial**: variáveis de evidência “abaixo” de  $X$  que estão conectadas a  $X$  através dos filhos.
- $E_{U_i|X}$ : evidências conectadas com todos os nós  $U_i$ , *exceto* via o ramo que passa por  $X$ .



# Inferência em Redes de Crenças


- Estratégia geral:
  - ▶ Representar  $\mathbf{P}(X | E)$  em termos de contribuições de  $E_X^+$  e  $E_X^-$ .
  - ▶ Computar a contribuição de  $E_X^+$  através do seu efeito nos pais de X. Obs: computar os efeitos dos pais de X em X pode ser feito de forma recursiva.
  - ▶ Computar a contribuição de  $E_X^-$  através do seu efeito nos pais de X. Obs: computar os efeitos dos pais de X em X pode ser feito de forma recursiva.
- Método: aplicar Bayes, outros métodos padrão de prob, simplificações (independência condicional).

## Inferência em Redes de Crenças

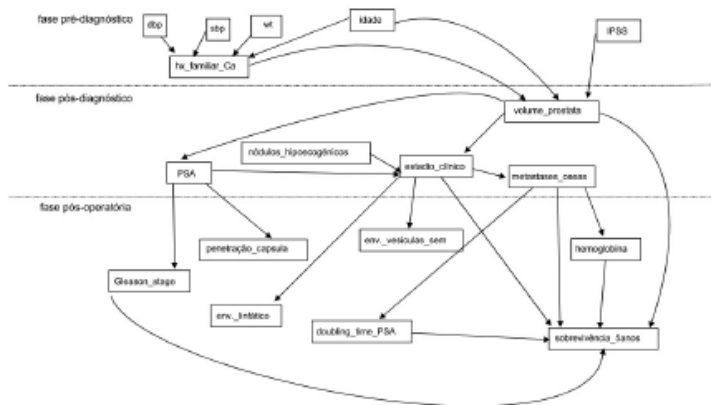
- $\mathbf{P}(X | E) = \mathbf{P}(X | E_X^-, E_X^+) = \frac{\mathbf{P}(E_X^- | X, E_X^+) \mathbf{P}(X | E_X^+)}{\mathbf{P}(E_X^- | E_X^+)}$
- Como X d-separa  $E_X^+$  de  $E_X^-$  na rede, podemos usar indep cond p/ simplificar primeiro termo do numerador. Tb podemos usar  $\frac{1}{\mathbf{P}(E_X^- | E_X^+)}$  como cte de normalização:  

$$\mathbf{P}(X | E) = \alpha \mathbf{P}(E_X^- | X) \mathbf{P}(X | E_X^+)$$
- $\mathbf{P}(X | E_X^+) = \sum_u \mathbf{P}(X | \mathbf{u}, E_X^+) P(\mathbf{u} | E_X^+)$
- $\mathbf{P}(X | E_X^+) = \sum_u \mathbf{P}(X | \mathbf{u}) \prod_i \mathbf{P}(u_i | E_X^+)$
- $\mathbf{P}(X | E_X^+) = \sum_u \mathbf{P}(X | \mathbf{u}) \prod_i \mathbf{P}(u_i | E_{U_i | X})$

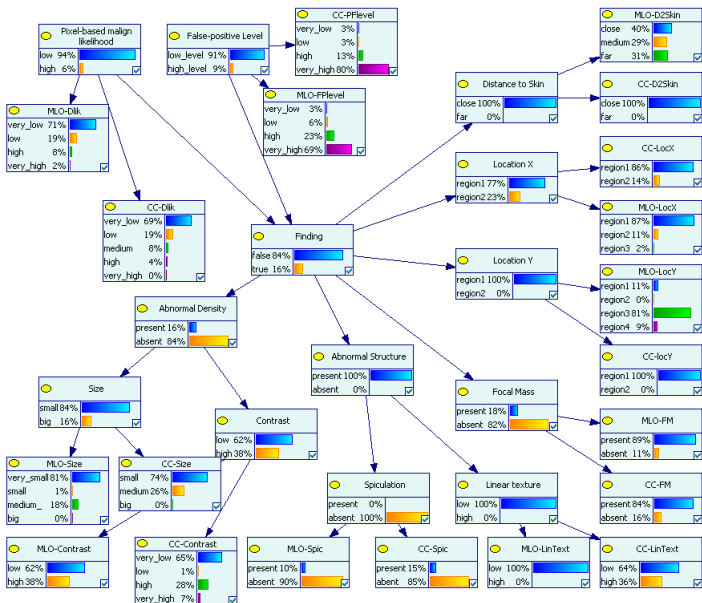
# Redes de Bayes



# Redes de Bayes



# Redes de Bayes



## *Decision Theory steps*

- **Create causal model**

- ▶ Determine possible symptoms, disorders, treatments, and outcomes.
- ▶ Draw arcs indicating what disorders cause what symptoms, and what treatments alleviate what disorders.
- ▶ Often the model will match well informal graphical descriptions given in medical textbooks.

## *Decision Theory steps*

- **Simplify to a qualitative decision model**
  - ▶ If we are using the model to make treatment decisions, we can often simplify the model by removing variables that are not involved in treatment decisions (discriminative model x generative model).

## *Decision Theory steps*

- **Assign probabilities**

- ▶ these can come from patient databases, literature studies or the expert's subjective assessments.
- ▶ (arguably) easier for humans: assess the probability of a cause given an effect (for example,  $P(S | M)$ ).
- ▶ diagnostic reasoning ( $P(S | M)$ ) performed by the Bayesian network inference algorithm.



## *Decision Theory steps*

- **Assign utilities**
  - ▶ for a small number of possible of outcomes: create a scale from best to worst and give each a numeric value between 0 and 1 (0 can be healthy person and 1 a person with a disease).
  - ▶ this can be done by an expert, but it is recommended to involve the patient.
  - ▶ if there are exponentially many outcomes, combine them to use multiattribute utility functions (for example, we may say that the costs of various comorbidities are additive).

## *Decision Theory steps*

- **Verify and refine the model**
  - ▶ need a set of correct (input, output) pairs: **gold standard** to compare against our outcomes.
  - ▶ medical conference meetings that decide on diagnosis and recommended treatment plan.
  - ▶ if the system does poorly, isolate parts that are going wrong and fix them.
  - ▶ verification can be done “backward”: instead of presenting symptoms and asking for a diagnosis, present the system with the diagnosis and examine the predicted probability of symptoms and compare with the medical literature.

## *Decision Theory steps*

- **Perform sensitivity analysis**
  - ▶ checks if the best decision is sensitive to small changes in the assigned probabilities and utilities by systematically varying those parameters and running the evaluation again.
  - ▶ if all variations lead to the same decision we can have some confidence that the system is taking the right decision.