

Inteligência Artificial

Aula 14
Profª Bianca Zadrozny
<http://www.ic.uff.br/~bianca/ia>

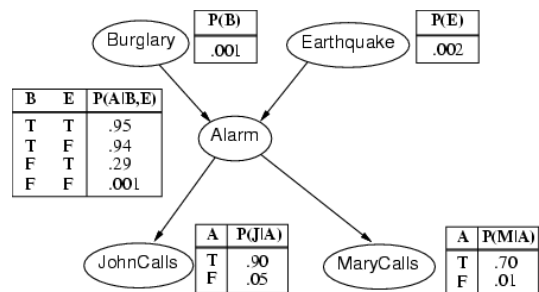
Raciocínio Probabilístico

Capítulo 14 – Russell & Norvig
Seções 14.3 a 14.5

Revisão: Redes Bayesianas

- Estrutura de dados para representar as dependências entre variáveis e fornecer uma especificação concisa de *qualquer* distribuição de probabilidade conjunta total.
- Sintaxe:
 - um conjunto de nós, um para cada variável aleatória
 - grafo direcionado e acíclico (seta = “influência direta”)
 - cada nó tem uma distribuição condicional $P(X_i | \text{Pais}(X_i))$ que quantifica o efeito dos pais sobre o nó
- No caso mais simples, a distribuição condicional é representada como uma **tabela de probabilidade condicional** (TPC) dada uma distribuição sobre X_i para cada combinação de valores dos pais.

Exemplo



Representação eficiente de distribuições condicionais

- Ainda que o número de pais k seja reduzido, o preenchimento da TPC para um nó exige até $O(2^k)$ e muita experiência para decidir os casos condicionais.
 - **Esse é o pior caso, em que os relacionamentos entre pais e filhos são arbitrários.**
- Em muitos casos podemos utilizar um padrão (**distribuição canônica**) para obter a tabela.

Representação eficiente de distribuições condicionais

- **Distribuição canônica:**
 - ajustar a distribuição de probabilidades em cada nó a alguma forma padrão.
 - nestes casos a tabela completa pode ser especificada nomeando-se o padrão e fornecendo-se alguns parâmetros.
 - Exemplos:
 - nós determinísticos
 - relacionamentos lógicos ruidosos: *ou-ruidoso*

Representação eficiente: Distribuição canônica

- **Nós determinísticos:** tem seus valores especificados pelos valores de seus pais, sem qualquer incerteza:
 - $X = f(\text{Pais}(X))$ para alguma função f ;
 - funções booleanas:
 - Norte Americano \Leftrightarrow Canadense \vee EUA \vee Mexicano
 - relação numérica entre funções contínuas:
 - **pais afluentes/escoadouros filhos:** $\Delta \text{nível da água}$
 - $\Delta \text{nível da água} = \text{afluentes} - \text{escoadouros}$
 - **Valor mínimo de alguma função**

Representação eficiente: Distribuição canônica

- **Ou-ruidoso**
 - $P(\neg \text{fever} | \text{cold}, \neg \text{flu}, \neg \text{malaria}) = 0.6$
 - $P(\neg \text{fever} | \neg \text{cold}, \text{flu}, \neg \text{malaria}) = 0.2$
 - $P(\neg \text{fever} | \neg \text{cold}, \neg \text{flu}, \text{malaria}) = 0.1$

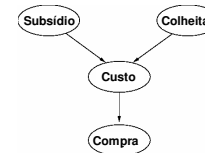
<i>Cold</i>	<i>Flu</i>	<i>Malaria</i>	$P(\text{Fever})$	$P(\neg \text{Fever})$
F	F	F	0.0	1.0
F	F	T	0.9	0.1
F	T	F	0.8	0.2
F	T	T	0.98	$0.02 = 0.2 \times 0.1$
T	F	F	0.4	0.6
T	F	T	0.94	$0.06 = 0.6 \times 0.1$
T	T	F	0.88	$0.12 = 0.6 \times 0.2$
T	T	T	0.988	$0.012 = 0.6 \times 0.2 \times 0.1$

Representação eficiente: Distribuição canônica

- **Ou-ruidoso (em contraste com o ou proposicional)**
 - Permite a incerteza sobre a habilidade de cada pai para fazer o filho ser verdadeiro - o relacionamento entre pai e filho pode ser inibido.
 - Todas as causas listadas
 - inibições independentes
 - Assim “febre é falsa se e somente se todos os seus pais verdadeiros são inibidos, e a probabilidade de isso ocorrer é o produto das probabilidades de inibição de cada pai.”

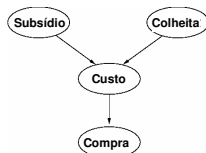
Redes de Bayes Híbridas

- Discretas: *Subsídio?* e *Compra?*



- Dois novos tipos de distribuições condicionais:
 - **variável contínua, com pais contínuos e discretos (Custo)**
 - **Variável discreta com pai contínuo (Compra?)**

Redes de Bayes Híbridas



- Manipular variáveis contínuas:
 - **Discretização:** repartir os valores possíveis em um conjunto fixo de intervalos
 - **Definir funções de probabilidade padrão** especificadas por um número finito de parâmetros

Variável contínua, com pais contínuos e discretos (Cost)

- Para custo: $P(\text{Custo} | \text{Colheita}, \text{Subsídio})$
 - O pai discreto (*Subsídio*) é manipulado por enumeração explícita:
 - $P(\text{Custo} | \text{Colheita}, \text{subsídio})$ e $P(\text{Custo} | \text{Colheita}, \neg \text{subsídio})$
- Para *Colheita* especificamos como a distribuição sobre o custo c depende do valor contínuo h de colheita.
 - i.e., os parâmetros da distribuição de custo como função de h
 - em geral: **distribuição Gaussiana linear**

Variável contínua, com pais contínuos e discretos (*Costo*)

- **distribuição gaussiana linear:** o filho (*Costo*) tem uma distribuição gaussiana cuja média varia linearmente com o valor do pai (*Colheita*), e cujo desvio padrão é fixo:

$$\begin{aligned}
 P(\text{Cost} = c | \text{Harvest} = h, \text{Subsidy?} = \text{true}) &= N(a_t h + b_t, \sigma_t)(c) \\
 &= \frac{1}{\sigma_t \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{c - (a_t h + b_t)}{\sigma_t}\right)^2\right)
 \end{aligned}$$

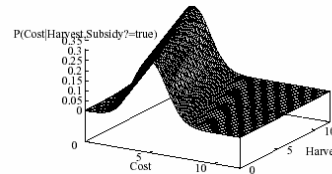
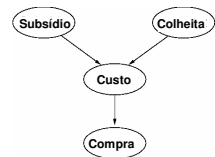
- **distribuição gaussiana linear:** o filho (*Costo*) tem uma distribuição gaussiana cuja média varia linearmente com o valor do pai (*Colheita*), e cujo desvio padrão é fixo:

$$\begin{aligned}
 P(\text{Cost} = c | \text{Harvest} = h, \text{Subsidy?} = \text{true}) &= N(a_t h + b_t, \sigma_t)(c) \\
 &= \frac{1}{\sigma_t \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{c - (a_t h + b_t)}{\sigma_t}\right)^2\right)
 \end{aligned}$$

- **distribuição gaussiana linear:** o filho (*Costo*) tem uma distribuição gaussiana cuja média varia linearmente com o valor do pai (*Colheita*), e cujo desvio padrão é fixo:

$$\begin{aligned}
 P(\text{Cost} = c | \text{Harvest} = h, \text{Subsidy?} = \text{true}) &= N(a_t h + b_t, \sigma_t)(c) \\
 &= \frac{1}{\sigma_t \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{c - (a_t h + b_t)}{\sigma_t}\right)^2\right)
 \end{aligned}$$

$$\begin{aligned}
 P(\text{Cost} = c | \text{Harvest} = h, \text{Subsidy?} = \text{true}) &= N(a_t h + b_t, \sigma_t)(c) \\
 &= \frac{1}{\sigma_t \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{c - (a_t h + b_t)}{\sigma_t}\right)^2\right)
 \end{aligned}$$



A inclinação é negativa, porque o preço diminui à medida que a quantidade oferecida aumenta

Distribuição gaussiana condicional linear

- Uma rede que contém apenas variáveis contínuas com distribuições Gaussianas lineares tem uma distribuição conjunta que é uma **distribuição multivariada** sobre todas as variáveis.
 - superfície em mais de uma dimensão que tem um pico na média (em n dimensões) e decresce para todos os lados.
- Com variáveis discretas (se nenhuma destas é filha de uma var. contínua), a rede define uma **distribuição gaussiana condicional**
 - dada qqr. atribuição às var. discretas, a distribuição sobre as var. contínuas é uma **distribuição gaussiana multivariada**.

variáveis discretas com pais contínuos

- Ex. *Compras*:
 - Podemos supor que o cliente comprará se o preço for baixo e não comprará se for alto e que:
 - A probabilidade de compra varia suavemente em alguma região intermediária
 - A distribuição condicional é semelhante a uma função de limiar “suave” (*soft threshold*)
 - Distribuição **probit** é uma possibilidade...

v. discretas, pais contínuos

- Probabilidade de *Compra* dado *Custo*: **limiar suave**
- Distribuição **Probit**:
 - integral da Gaussiana
 - posição precisa do limiar está sujeita a ruído gaussiano

$$\Phi(x) = \int_{-\infty}^x N(0, 1)(x)dx$$

$$P(\text{Buys?} = \text{true} \mid \text{Cost} = c) = \Phi((-c + \mu)/\sigma)$$

Por que **Probit**?

- Possui mais ou menos o formato desejado
- Pode ser visto como um degrau cuja posição tem ruído.

Inferência Bayesiana

- Dada uma rede bayesiana, queremos computar a distribuição da probabilidade condicional para um conjunto de variáveis de consulta, dado os valores de um conjunto de variáveis de evidência:

P(Variável_consulta | Variáveis_Evidência)

Inferência Exata: Algoritmo de Enumeração

- A idéia básica do algoritmo de Enumeração é avaliar a equação

$$P(X | E) = \alpha \sum_y P(X, e, y)$$

sem ter que montar explicitamente a tabela de probabilidade conjunta total.

- Apenas, percorrem-se os nós da rede propagando as evidências e extraíndo as probabilidades para que sejam feitos os somatórios e multiplicações necessárias.

Algoritmo de Enumeração

$$P(B|J,M)?? \longrightarrow P(B|j,m) = \alpha P(B, j, m) = \alpha \sum_e \sum_a P(B, e, a, j, m)$$

$$= \alpha \sum B P(B)P(a|B,e)P(m|a)P(j|a)$$

(calcular para cada valor de B (b e ¬b) e normalizar)

Algoritmo de Enumeração

A figura torna explícita as sub-expressões repetidas que são avaliadas pelo algoritmo. Os produtos $P(j|a)P(m|a)$ e $P(j|\neg a)P(m|\neg a)$ são calculados duas vezes, um para cada valor de e.

Algoritmo de Enumeração

```
function ENUMERATE-ASK( $X, e, bn$ ) returns a distribution over  $X$ 
inputs:  $X$ , the query variable
        $e$ , observed values for variables  $E$ 
        $bn$ , a Bayesian network with variables  $\{X\} \cup E \cup Y$ 
 $Q(X) \leftarrow$  a distribution over  $X$ , initially empty
for each value  $x_i$  of  $X$  do
  extend  $e$  with value  $x_i$  for  $X$ 
   $Q(x_i) \leftarrow$  ENUMERATE-ALL(VARS[bn],  $e$ )
return NORMALIZE( $Q(X)$ )
```

```
function ENUMERATE-ALL( $vars, e$ ) returns a real number
if EMPTY?( $vars$ ) then return 1.0
 $Y \leftarrow$  FIRST( $vars$ )
if  $Y$  has value  $y$  in  $e$ 
  then return  $P(y | Pa(Y)) \times$  ENUMERATE-ALL(REST( $vars$ ),  $e$ )
  else return  $\sum_y P(y | Pa(Y)) \times$  ENUMERATE-ALL(REST( $vars$ ),  $e_y$ )
  where  $e_y$  is  $e$  extended with  $Y = y$ 
```

Algoritmo de Eliminação de Variáveis

- Elimina os cálculos repetidos do algoritmo de enumeração.
- A idéia é simples: efetuar o cálculo apenas uma vez e guardar os resultados para uso posterior.
- Esta é uma forma de programação dinâmica.

Algoritmo de Eliminação de Variáveis

Problemas do algoritmo de eliminação de variáveis:

- A configuração inicial das variáveis influencia no tempo de execução dos algoritmos.
- Encontrar uma configuração inicial ótima é um problema NP-Completo.