

## Inteligência Artificial

Aula 9  
 Profª Bianca Zadrozny  
<http://www.ic.uff.br/~bianca/ia-pos>

## Raciocínio Probabilístico

Capítulo 14 – Russell & Norvig  
 Seções 14.1 a 14.4

Aula 9 - 16/11/10

2

## 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
    - **tabela de probabilidade condicional** (TPC)

Aula 9 - 16/11/10

3

## Exemplo

- A topologia de uma rede representa relações de independência condicional:



- *Clima* é independente de outras variáveis
- *DorDeDente* e *Boticão* são condicionalmente independentes dado *Cárie*
- Informalmente, a rede representa o fato de que *Cárie* é uma causa direta de *DorDeDente* e *Boticão*.

Aula 9 - 16/11/10

4


## Exemplo

- “Estou no trabalho, meu vizinho João me liga pra dizer que o alarme da minha casa está tocando, mas a minha vizinha Maria não me liga. Às vezes o alarme toca por causa de terremotos leves. Houve um roubo na minha casa?”
- Variáveis: *Roubo* (*Burglary*), *Terremoto* (*Earthquake*), *Alarme* (*Alarm*), *JoãoLiga* (*JohnCalls*), *MariaLiga* (*MaryCalls*)
- A topologia da rede reflete conhecimento “causal”:
  - Um roubo pode ativar o alarme
  - Um terremoto pode ativar o alarme
  - O alarme faz Maria telefonar
  - O alarme faz João telefonar

Aula 9 - 16/11/10

5

## Exemplo



Aula 9 - 16/11/10

6

## Da topologia da rede

- Roubos e terremotos afetam diretamente a probabilidade do alarme tocar.
- Mas o fato de João e Maria telefonarem só depende do alarme.
- Desse modo, **a rede representa nossas suposições de que eles não percebem quaisquer roubos diretamente, não notam os terremotos e não verificam antes de ligar!**

Aula 9 - 16/11/10

7

## As probabilidades...

- ... resumem um conjunto potencialmente infinito de circunstâncias (Maria ouve música alta, João liga quando ouve o telefone tocar; umidade, falta de energia, etc., podem interferir no alarme; João e Maria não estão em casa, etc.
  - “Preguiça e ignorância”

Aula 9 - 16/11/10

8

## Tabelas de probabilidade condicional (TPC)

- Cada linha em uma TPC contém a probabilidade condicional de cada valor de nó para um **caso de condicionamento**;
  - um caso de condicionamento é uma combinação possível de valores para os nós superiores
- Cada linha requer um número  $p$  para  $X_i = true$  (a probabilidade para  $X_i = false$  é  $1-p$ )

Aula 9 - 16/11/10

9

## Tabelas de probabilidade condicional (TPC)

- Um nó sem pais tem apenas uma linha: probabilidade a priori
- Em geral, uma tabela para uma variável booleana com  $k$  pais booleanos possui  $2^k$  probabilidades
- Se cada variável não possui mais do que  $k$  pais, a rede completa será  $O(n \cdot 2^k)$ , para  $n =$  número de nós.
  - i.e., cresce linearmente com  $n$ , vs.  $O(2^n)$  da distribuição total

Aula 9 - 16/11/10

10

## Semântica das RB

- Duas maneiras equivalentes:
  - **Semântica global** (ou numérica): entender as redes como uma representação da distribuição de probabilidade conjunta.
    - Indica como construir uma rede.
  - **Semântica local** (ou topológica): visualizá-las como uma codificação de uma coleção de declarações de independência condicional.
    - Indica como fazer inferências com uma rede.

Aula 9 - 16/11/10

11

## Semântica Global

Se uma rede bayesiana for uma representação da distribuição conjunta, então ela poderá ser utilizada para responder qualquer consulta efetuando-se o **produtório** de todas as entradas conjuntas relevantes.



Aula 9 - 16/11/10

12

### Semântica Global

A semântica global (ou numérica) define a distribuição de probabilidade total como o produto das distribuições condicionais locais:

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | Pais(X_i))$$



Aula 9 - 16/11/10

13

### Semântica Global

A semântica global (ou numérica) define a distribuição de probabilidade total como o produto das distribuições condicionais locais:

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | Pais(X_i))$$



e.g.,  $P(j \wedge m \wedge a \wedge \neg b \wedge \neg e)$   
 $= P(j | a) P(m | a) P(a | \neg b, \neg e) P(\neg b) P(\neg e)$   
 $= 0.9 \times 0.7 \times 0.001 \times 0.999 \times 0.998$   
 $= 0.00063$

Aula 9 - 16/11/10

14

### Semântica local


- **Semântica local** (topológica): cada nó é condicionalmente independente de seus não-descendentes, dados seus pais. Ex. J é independente de B e E dado A.



Aula 9 - 16/11/10

15

### Semântica local




Um nó X é condicionalmente independente de seus não descendentes (Z<sub>ij</sub>) dados seus pais (U<sub>i</sub>).

Aula 9 - 16/11/10

16

### Semântica local



Um nó X é condicionalmente independente de todos os outros nós dada a sua **cobertura de Markov** (=pais, filhos e pais dos filhos)

Aula 9 - 16/11/10

17

### Semântica local e global

- A partir dessas asserções sobre a independência condicional e das TPCs, a distribuição conjunta pode ser reconstruída. – Deste modo a semântica numérica e topológica são equivalentes.

Aula 9 - 16/11/10

18

### Construindo uma rede Bayesiana

1. Escolha uma ordem para as variáveis aleatórias  $X_1, \dots, X_n$
2. Para  $i = 1$  a  $n$ 
  - adicione  $X_i$  à rede
  - selecione pais para  $X_1, \dots, X_{i-1}$  tais que

$$P(X_i | Pais(X_i)) = P(X_i | X_1, \dots, X_{i-1})$$

Esta escolha de pais garante a semântica global:

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | X_1, \dots, X_{i-1}) \text{ (regra da cadeia)}$$

$$= \prod_{i=1}^n P(X_i | Pais(X_i)) \text{ (por construção)}$$

### Ordem para as variáveis

- A ordem correta em que os nós devem ser adicionados consiste em adicionar primeiro as “causas de raiz”, depois as variáveis que elas influenciam e assim por diante, até chegarmos às folhas, que não tem nenhuma influência causal direta sobre as outras variáveis.
- E se escolhermos a ordem “errada”?

### Exemplo


- Assumindo a ordem:  $M, J, A, B, E$



$$P(J | M) = P(J)?$$

### Exemplo

- Assumindo a ordem:  $M, J, A, B, E$




$$P(J | M) = P(J)? \text{ Não}$$

$$P(A | J, M) = P(A | J)? \quad P(A | J, M) = P(A)?$$

### Exemplo

- Assumindo a ordem:  $M, J, A, B, E$



$$P(J | M) = P(J)? \text{ Não}$$


$$P(A | J, M) = P(A | J)? \quad P(A | J, M) = P(A)? \text{ Não}$$

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

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

### Exemplo

- Assumindo a ordem:  $M, J, A, B, E$



$$P(J | M) = P(J)? \text{ Não}$$

$$P(A | J, M) = P(A | J)? \quad P(A | J, M) = P(A)? \text{ Não}$$


$$P(B | A, J, M) = P(B | A)? \text{ Sim}$$

$$P(B | A, J, M) = P(B)? \text{ Não}$$

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

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

### Exemplo



$P(J | M) = P(J)$ ? Não

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

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

$P(B | A, J, M) = P(B)$ ? Não


$P(E | B, A, J, M) = P(E | A)$ ? Não

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

Aula 9 - 16/11/10

25

### Exemplo




- A rede resultante terá dois vínculos a mais que a rede original e exigirá outras probabilidades para serem especificadas
- Alguns dos vínculos apresentam relacionamentos tênues que exigem julgamentos de probabilidade difíceis e antinaturais (prob de Terremoto, dados Roubo e Alarme)
- (Em geral) é melhor pensar de causas para efeitos (modelo causal) e não do contrário (modelo de diagnóstico)

Aula 9 - 16/11/10

26

### Exemplo



- Uma ordenação de nós ruim: *MaryCalls, JohnCalls, Earthquake, Burglary e Alarm*
- Entretanto, todas as três redes devem representar a mesma distribuição conjunta. As duas últimas só não expressam todas as independências condicionais

Aula 9 - 16/11/10

27

### 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.

Aula 14 - 08/10/10

28

### 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*

Aula 14 - 08/10/10

29

### 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:**  $\Delta$ nível da água
      - $\Delta$ nível da água = afluentes - escoadouros
    - Valor mínimo de alguma função

Aula 14 - 08/10/10

30

## Representação eficiente: Distribuição canônica

- **Ou-ruído**

- $P(\neg\text{fever} \mid \text{cold}, \neg\text{flu}, \neg\text{malaria}) = 0.6$
- $P(\neg\text{fever} \mid \neg\text{cold}, \text{flu}, \neg\text{malaria}) = 0.2$
- $P(\neg\text{fever} \mid \neg\text{cold}, \neg\text{flu}, \text{malaria}) = 0.1$

Cold	Flu	Malaria	$P(\text{Fever})$	$P(\neg\text{Fever})$
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	$0.012 = 0.6 \times 0.2 \times 0.1$

31

## Representação eficiente: Distribuição canônica

- **Ou-ruído** (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.”

Aula 14 - 08/10/10

32

## 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?)**

Aula 14 - 08/10/10

33

## 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

Aula 14 - 08/10/10

34

## Variável contínua, com pais contínuos e discretos (Cost)

- Para custo:  $P(\text{Custo} \mid \text{Colheita}, \text{Subsídio})$ 
  - O pai discreto (*Subsídio*) é manipulado por enumeração explícita:
 
$$P(\text{Custo} \mid \text{Colheita}, \text{subsídio}) \text{ e } P(\text{Custo} \mid \text{Colheita}, \neg\text{subsídio})$$
- 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**

Aula 14 - 08/10/10

35

## Variável contínua, com pais contínuos e discretos (Custo)

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

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

Aula 14 - 08/10/10

36

- **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:

$$P(\text{Cost} = c | \text{Harvest} = h, \text{Subsidy} = \text{true}) = N(a_1 h + b_1, \sigma_1)(c) = \frac{1}{\sigma_1 \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{c - (a_1 h + b_1)}{\sigma_1}\right)^2\right)$$

Aula 14 - 08/10/10

37



- **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:

$$P(\text{Cost} = c | \text{Harvest} = h, \text{Subsidy} = \text{true}) = N(a_1 h + b_1, \sigma_1)(c) = \frac{1}{\sigma_1 \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{c - (a_1 h + b_1)}{\sigma_1}\right)^2\right)$$

Aula 14 - 08/10/10

38

$$P(\text{Cost} = c | \text{Harvest} = h, \text{Subsidy} = \text{true}) = N(a_1 h + b_1, \sigma_1)(c) = \frac{1}{\sigma_1 \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{c - (a_1 h + b_1)}{\sigma_1}\right)^2\right)$$



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

Aula 14 - 08/10/10

39

### 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**.

Aula 14 - 08/10/10

40


### 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...

Aula 14 - 08/10/10

41

### v. discretas, pais contínuos



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

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


$$P(\text{Buys} = \text{true} | \text{Cost} = c) = \Phi\left(\frac{-c + \mu}{\sigma}\right)$$

Aula 14 - 08/10/10

42

### Por que Probit?

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



Aula 14 - 08/10/10

43

### 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:

$$P(\text{Variável\_consulta} | \text{Variáveis\_Evidência})$$

Aula 14 - 08/10/10

44

### 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 extraindo as probabilidades para que sejam feitos os somatórios e multiplicações necessárias.

45

Aula 14 - 08/10/10

### Algoritmo de Enumeração



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


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

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

Aula 14 - 08/10/10

46

### 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  $e$ .

Aula 14 - 08/10/10

47

### Algoritmo de Enumeração

```
function ENUMERATION-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  $\{X\} \cup E \cup Y$ 
 $Q(X)$  — a distribution over  $X$ , initially empty
for each value  $x_i$  of  $X$  do
  extend  $e$  with value  $x_i$  for  $X$ 
   $Q(x_i)$  ← 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
 $Y$  ← FIRST( $vars$ )
if  $Y$  has value  $y$  in  $e$ 
  then return  $P(y | Pa(Y)) \times$  ENUMERATE-ALL(REST( $vars$ ),  $e$ )
else return  $\sum_{e_y} P(y | Pa(Y)) \times$  ENUMERATE-ALL(REST( $vars$ ),  $e_y$ )
       where  $e_y$  is  $e$  extended with  $Y = y$ 
```

Aula 14 - 08/10/10

48

### 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.

Aula 14 - 08/10/10

49

### 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.

Aula 14 - 08/10/10

50