

# Inteligencia Artificial

## Razonamiento probabilístico

Primavera 2008

profesor: Luigi Ceccaroni



# Inferencia probabilística

Las leyes de la probabilidad permiten establecer diferentes métodos de inferencia

- **Marginalización:** Probabilidad de una proposición atómica con independencia de los valores del resto de proposiciones

$$P(Y) = \sum_z P(Y, z)$$

- **Probabilidades condicionadas:** Probabilidad de una proposición dados unos valores para algunas proposiciones e independiente del resto de proposiciones (a partir de la regla del producto)

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

El valor  $\alpha$  es un factor de normalización que corresponde a factores comunes que hacen que las probabilidades sumen 1

# Inferencia probabilística: ejemplo

Consideremos un problema en el que intervengan las proposiciones  
 $Fumador = \{fumador, \neg fumador\}$ ,  $Sexo = \{varon, mujer\}$ ,  
 $Enfisema = \{enfisema, \neg enfisema\}$

	<i>enfisema</i>		$\neg$ <i>enfisema</i>	
	<i>varon</i>	<i>mujer</i>	<i>varon</i>	<i>mujer</i>
<i>fumador</i>	0.2	0.1	0.05	0.05
$\neg$ <i>fumador</i>	0.02	0.02	0.23	0.33

# Inferencia probabilística: ejemplo

$$P(\text{enfisema} \wedge \text{varon}) = 0,2 + 0,02$$

$$P(\text{fumador} \vee \text{mujer}) = 0,2 + 0,1 + 0,05 + 0,05 + 0,02 + 0,33$$

$$\begin{aligned} P(\text{Fumador}|\text{enfisema}) &= \langle P(\text{fumador}, \text{enfisema}, \text{varon}) \\ &\quad + P(\text{fumador}, \text{enfisema}, \text{mujer}), \\ &\quad P(\neg\text{fumador}, \text{enfisema}, \text{varon}) \\ &\quad + P(\neg\text{fumador}, \text{enfisema}, \text{mujer}) \rangle \\ &= \alpha\langle 0,3, 0,04 \rangle \\ &= \langle 0,88, 0,12 \rangle \end{aligned}$$

# La regla de Bayes

- Hemos enunciado la regla del producto como:

$$P(X, Y) = P(X|Y)P(Y) = P(Y|X)P(X)$$

- Esto nos lleva a lo que denominaremos la **regla de Bayes**

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

- Esta regla y la propiedad de independencia serán el fundamento del razonamiento probabilístico y nos permitirá relacionar las probabilidades de unas evidencias con otras

# La regla de Bayes + independencia

- Suponiendo que podemos estimar exhaustivamente todas las probabilidades que involucran la variable  $Y$  podemos reescribir la fórmula de Bayes como:

$$P(Y|X) = \alpha P(X|Y)P(Y)$$

- Suponiendo independencia condicional entre dos variables podremos escribir:

$$P(X, Y|Z) = P(X|Z)P(Y|Z)$$

- De manera que:

$$P(Z|X, Y) = \alpha P(X|Z)P(Y|Z)P(Z)$$

# Redes Bayesianas

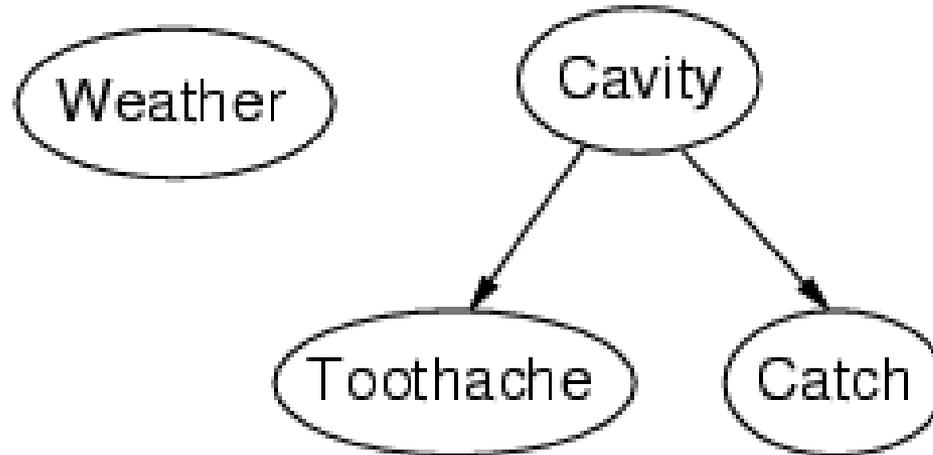
- A simple, graphical notation for conditional independence assertions and hence for compact specification of full joint distributions.
- Syntax:
  - a set of nodes, one per variable
  - a directed, acyclic graph (links  $\approx$  "directly influences")
  - a conditional distribution for each node given its parents:  
$$P(X_i | \text{Parents}(X_i))$$
- In the simplest case, conditional distribution represented as **conditional probability tables** (CPTs) giving the distribution over  $X_i$  for each combination of parent values.

# Redes Bayesianas

- Si determinamos la independencia entre variables podemos simplificar el cálculo de la combinación de sus probabilidades y su representación
- Las **redes bayesianas** permiten la representación de las relaciones de independencia entre variable aleatorias
- Una red bayesiana es un **grafo dirigido acíclico** que tiene información probabilística en sus nodos indicando cual es la influencia de sus padres en el grafo sobre el nodo ( $P(X_i|padres(X_i))$ )
- El significado intuitivo de un enlace entre dos nodos  $X$  e  $Y$  es que la variable  $X$  tiene influencia sobre  $Y$
- El conjunto de probabilidades representadas en la red describe la distribución de probabilidad conjunta de todas las variables

# Ejemplo

- Topology of network encodes conditional independence assertions:



- *Weather* is independent of the other variables.
- *Toothache* and *Catch* are conditionally independent given *Cavity*.

# Tamaño reducido

- A CPT for Boolean  $X_i$  with  $k$  Boolean parents has  $2^k$  rows for the combinations of parent values.
- Each row requires one number  $p$  for  $X_i = \text{true}$  (the number for  $X_i = \text{false}$  is just  $1-p$ ).
- If each of the  $n$  variables has no more than  $k$  parents, the complete network requires  $O(n \cdot 2^k)$  numbers.
- I.e., grows linearly with  $n$ , vs.  $O(2^n)$  for the full joint distribution.

# Semántica

The full joint distribution is defined as the product of the local conditional distributions:

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

e.g.,

$$\begin{aligned} & P(d \wedge A=\text{equilibrada} \wedge P=\text{alta} \wedge \neg f \wedge \neg i) \\ &= P(d) P(A=\text{balanced}) P(P=\text{alta}|d, \\ & A=\text{equilibrada}) P(\neg f) P(\neg i|P=\text{alta}, \neg f) \end{aligned}$$

# Construcción de redes Bayesianas

- 1. Choose an ordering of variables  $X_1, \dots, X_n$
- 2. For  $i = 1$  to  $n$ 
  - add  $X_i$  to the network
  - select parents from  $X_1, \dots, X_{i-1}$  such that

$$\mathbf{P}(X_i \mid \text{Parents}(X_i)) = \mathbf{P}(X_i \mid X_1, \dots, X_{i-1})$$

This choice of parents guarantees:

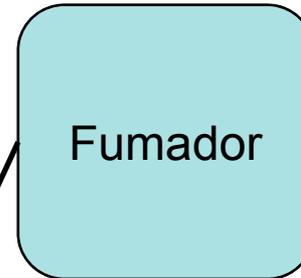
$$\begin{aligned} \mathbf{P}(X_1, \dots, X_n) &= \prod_{i=1}^n \mathbf{P}(X_i \mid X_1, \dots, X_{i-1}) \text{ (chain rule)} \\ &= \prod_{i=1}^n \mathbf{P}(X_i \mid \text{Parents}(X_i)) \text{ (by construction)} \end{aligned}$$

# Ejemplo

Deporte	P(D)
sí	0.1
no	0.9



Alimentación	P(A)
equilibrada	0.4
no equilibrada	0.6



Fumador	P(F)
sí	0.4
no	0.6



Pr. Sang.	Fum.	P(I=sí)	P(I=no)
alta	sí	0.8	0.2
norm.	sí	0.6	0.4
alta	no	0.7	0.3
norm.	no	0.3	0.7

Alim.	Deporte	P (S=alta)	P (S=normal)
eq.	sí	0.01	0.99
no eq.	sí	0.2	0.8
eq.	no	0.25	0.75
no eq.	no	0.7	0.3

# Redes Bayesianas - Distribución conjunta - ejemplo

$$\begin{aligned} &P(\text{Infarto} = \text{si} \wedge \text{Presion} = \text{alta} \wedge \text{Fumador} = \text{si} \\ &\wedge \text{Deporte} = \text{si} \wedge \text{Alimentacion} = \text{equil}) \\ &= \\ &P(\text{Infarto} = \text{si} | \text{Presion} = \text{alta}, \text{Fumador} = \text{si}) \\ &P(\text{Presion} = \text{alta} | \text{Deporte} = \text{si}, \text{Alimentacion} = \text{equil}) \\ &P(\text{Fumador} = \text{si})P(\text{Deporte} = \text{si})P(\text{Alimentacion} = \text{equil}) \\ &= 0,8 \times 0,01 \times 0,4 \times 0,1 \times 0,4 \\ &= 0,000128 \end{aligned}$$

# Coste de representación

- Como comentamos, el coste de representar la distribución de probabilidad conjunta de  $n$  variables binarias es  $O(2^n)$
- La representación de redes bayesianas nos permite una representación mas compacta gracias a la factorización de la distribución conjunta
- Suponiendo que cada nodo de la red tenga como máximo  $k$  padres ( $k \ll n$ ), un nodo necesitará  $2^k$  para representar la influencia de sus padres, por lo tanto el espacio necesario será  $O(n2^k)$ .
- Por ejemplo, con 10 variables y suponiendo 3 padres como máximo tenemos 80 frente a 1024, con 100 variables y suponiendo 5 padres tenemos 3200 frente a aproximadamente  $10^{30}$

# Inferencia Exacta

- **Inferencia por enumeración:** Cualquier probabilidad condicionada se puede calcular como la suma de todos los posibles casos a partir de la distribución de probabilidad conjunta.

$$P(X|\mathbf{e}) = \alpha P(X, \mathbf{e}) = \alpha \sum_y P(X, \mathbf{e}, \mathbf{y})$$

- La red bayesiana nos permite factorizar la distribución de probabilidad conjunta y obtener una expresión mas fácil de evaluar
- Usando la red bayesiana ejemplo podemos calcular la probabilidad de ser fumador si se ha tenido un infarto y no se hace deporte

$$P(\text{Fumador} | \text{Infarto} = \text{si}, \text{Deporte} = \text{no})$$

## Inferencia Exacta: Ejemplo

La distribución de probabilidad conjunta de la red sería:

$$P(D, A, S, F, I) = P(I|S, F)P(F)P(S|D, A)P(D)P(A)$$

Debemos calcular  $P(F|I = si, D = no)$ , por lo tanto tenemos

$$\begin{aligned} P(F|I = s, D = n) &= \alpha P(F, I = s, D = n) \\ &= \alpha \sum_{A \in \{e, \neg e\}} \sum_{S \in \{a, n\}} P(D = n, A, S, F, I = s) \\ &= \alpha P(D = n)P(F) \sum_{A \in \{e, \neg e\}} P(A) \sum_{S \in \{a, n\}} P(S|D = n, A)P(I = s|S, F) \end{aligned}$$

## Inferencia Exacta: Ejemplo

Si enumeramos todas las posibilidades y las sumamos de acuerdo con la distribución de probabilidad conjunta tenemos que:

$$\begin{aligned}
 & P(\text{Fumador} | \text{Infarto} = \text{si}, \text{Deporte} = \text{no}) \\
 &= \alpha \langle 0,9 \cdot 0,4 \cdot (0,4 \cdot (0,25 \cdot 0,8 + 0,75 \cdot 0,6)) + 0,6 \cdot (0,7 \cdot 0,8 + 0,3 \cdot 0,6) \rangle \\
 &\quad 0,9 \cdot 0,6 \cdot (0,4 \cdot (0,25 \cdot 0,7 + 0,75 \cdot 0,3)) + 0,6 \cdot (0,7 \cdot 0,7 + 0,3 \cdot 0,3) \rangle \\
 &= \alpha \langle 0,253, 0,274 \rangle \\
 &= \langle 0,48, 0,52 \rangle
 \end{aligned}$$

# Algoritmo de eliminación de variables

- El **algoritmo de eliminación de variables** intenta evitar la repetición de cálculos que realiza la inferencia por enumeración
- El algoritmo utiliza técnicas de programación dinámica de manera que se guardan cálculos intermedios para cada variable para reutilizarlos (*factores*)
- ~~El cálculo de la probabilidad de la pregunta se realiza evaluando la expresión de la distribución de probabilidad conjunta de izquierda a derecha~~
- Los *factores* correspondientes a cada variable se van acumulando según se necesita
- La ventaja de este algoritmo es que las variables no relevantes desaparecen al ser factores constantes

## Algoritmo de eliminación de variables

```
funcion ELIMINACION-Q( $X, e, rb$ ) retorna distribucion sobre  $X$   
   $factores = []$ ;  $vars = REVERSE(VARS(rb))$   
  para cada  $var$  en  $vars$  hacer  
     $factores = concatena(factores, CALCULA-FACTOR(var, e))$   
    si  $var$  es variable oculta entonces  
       $factores = PRODUCTO-Y-SUMA(var, factores)$   
  retorna NORMALIZA(PRODUCTO( $factores$ ))
```

- CALCULA-FACTOR genera el factor correspondiente a la variable en la función de la distribución de probabilidad conjunta
- PRODUCTO-Y-SUMA multiplica los factores y suma respecto a la variable oculta
- PRODUCTO multiplica un conjunto de factores

# Algoritmo de eliminación de variables - Factores

- Un factor corresponde a la probabilidad de un conjunto de variables dadas las variables ocultas
- Se representa por una tabla que para cada combinación de variables ocultas da la probabilidad de las variables del factor

$$f_X(Y, Z) =$$

Y	Z	
C	C	0.2
C	F	0.4
F	C	0.8
F	F	0.6

- Los factores tienen dos operaciones: suma y producto

# Suma de Factores

- La suma se aplica a un factor y sobre una variable oculta del factor. Como resultado obtenemos una matriz reducida en la que las filas del mismo valor se han acumulado

$$f_{X\bar{Z}}(Y) = \sum_Z f_X(Y, Z) = \begin{array}{c|c} Y & \\ \hline C & 0.6 \\ F & 1.4 \end{array}$$

- Es igual que una operación de agregación sobre una columna en bases de datos

## Producto de Factores

- El producto de factores permite juntar varios factores entre ellos utilizando las variables ocultas comunes

$$f_{X_1 X_2}(Y, W, Z) = f_{X_1}(Y, Z) \times f_{X_2}(Z, W) =$$

Y	Z		Z	W		Y	Z	W	
C	C	0.2	C	C	0.3	C	C	C	$0,2 \times 0,3$
C	F	0.8	C	F	0.7	C	C	F	$0,2 \times 0,7$
F	C	0.4	F	C	0.1	C	F	C	$0,8 \times 0,1$
F	F	0.6	F	F	0.9	C	F	F	$0,8 \times 0,9$
						F	C	C	$0,4 \times 0,3$
						F	C	F	$0,4 \times 0,7$
						F	F	C	$0,6 \times 0,9$
						F	F	F	$0,6 \times 0,3$

- Es igual que una operación de join en una base de datos multiplicando los valores de las columnas de datos

## Algoritmo de eliminación de variables - ejemplo

Volveremos a calcular  $P(\text{Fumador} | \text{Infarto} = \text{si}, \text{Deporte} = \text{no})$  a partir de la distribución de probabilidad conjunta:

$$P(D, A, S, F, I) = P(I|S, F)P(F)P(S|D, A)P(D)P(A)$$

Debemos calcular  $P(F|I = \text{si}, D = \text{no})$ , por lo tanto tenemos

$$\begin{aligned} P(F|I = s, D = n) &= \alpha P(I = s, F, D = n) \\ &= \alpha \sum_{A \in \{e, \neg e\}} \sum_{S \in \{a, n\}} P(D = n, A, S, F, I = s) \end{aligned}$$

En esta ocasión no sacamos factores comunes para seguir el algoritmo

$$\alpha P(D = n) \sum_{A \in \{e, \neg e\}} P(A) \sum_{S \in \{a, n\}} P(S|D = n, A)P(F)P(I = s|S, F)$$

## Algoritmo de eliminación de variables - ejemplo

El algoritmo empieza calculando el factor para la variable *Infarto* ( $P(I = s|S, F)$ ), esta tiene fijo su valor a si, depende de las variables *Presión Sanguinea* y *Fumador*

$$f_I(S, F) =$$

S	F	
a	s	0.8
a	n	0.7
n	s	0.6
n	n	0.3

La variable fumador ( $P(F)$ ) no depende de ninguna otra variable, al ser la variable que preguntamos el factor incluye todos los valores

$$f_F(F) =$$

F	
s	0.4
n	0.6

## Algoritmo de eliminación de variables - ejemplo

La variable *Presión Sanguinea* ( $P(S|D = n, A)$ ), depende de las variable *Deporte* que tiene fijo su valor a no y *Alimentación*. Esta es una variable oculta, por lo que se debe calcular para todos sus valores

$$f_S(S, A) =$$

S	A	
a	e	0.25
a	¬e	0.7
n	e	0.75
n	¬e	0.3

Al ser la variable *Presión Sanguinea* una variable oculta debemos acumular todos los factores que hemos calculado

$$f_S(S, A) \times f_F(F) \times f_I(S, F)$$

# Algoritmo de eliminación de variables - ejemplo

$$f_{FI}(S, F) = f_F(F) \times f_I(S, F) =$$

S	F	
a	s	$0.8 \times 0.4$
a	n	$0.7 \times 0.6$
n	s	$0.6 \times 0.4$
n	n	$0.3 \times 0.6$

$$f_{FIS}(S, F, A) = f_{FI}(S, F) \times f_S(S, A) =$$

S	F	A	
a	s	e	$0.8 \times 0.4 \times 0.25$
a	s	$\neg e$	$0.8 \times 0.4 \times 0.7$
a	n	e	$0.7 \times 0.6 \times 0.25$
a	n	$\neg e$	$0.7 \times 0.6 \times 0.7$
n	s	e	$0.6 \times 0.4 \times 0.75$
n	s	$\neg e$	$0.6 \times 0.4 \times 0.3$
n	n	e	$0.3 \times 0.6 \times 0.75$
n	n	$\neg e$	$0.3 \times 0.6 \times 0.3$

## Algoritmo de eliminación de variables - ejemplo

Y ahora sumamos sobre todos los valores de la variable  $S$  para obtener el factor correspondiente a la variable *Presión Sanguinea*

$$f_{FIS}(F, A) = \sum_{S \in \{a, n\}} f_{FIS}(S, F, A) =$$

F	A	
s	e	$0.8 \times 0.4 \times 0.25 + 0.6 \times 0.4 \times 0.75 = 0.26$
s	$\neg e$	$0.8 \times 0.4 \times 0.7 + 0.6 \times 0.4 \times 0.3 = 0.296$
n	e	$0.7 \times 0.6 \times 0.25 + 0.3 \times 0.6 \times 0.75 = 0.24$
n	$\neg e$	$0.7 \times 0.6 \times 0.7 + 0.3 \times 0.6 \times 0.3 = 0.348$

## Algoritmo de eliminación de variables - ejemplo

El factor de la variable *Alimentación* ( $P(A)$ ) no depende de ninguna variable, al ser una variable oculta generamos todas las posibilidades

$$f_A(A) = \begin{array}{c|c} F & \\ \hline e & 0.4 \\ \neg e & 0.6 \end{array}$$

Ahora debemos acumular todos los factores calculados

$$f_{AFIS}(A) = f_A(A) \times f_{FIS}(F, A) = \begin{array}{cc|c} F & A & \\ \hline s & e & 0.26 \times 0.4 = 0.104 \\ s & \neg e & 0.296 \times 0.6 = 0.177 \\ n & e & 0.24 \times 0.4 = 0.096 \\ n & \neg e & 0.348 \times 0.6 = 0.208 \end{array}$$

## Algoritmo de eliminación de variables - ejemplo

Y ahora sumamos sobre todos los valores de la variable  $A$  para obtener el factor correspondiente a la variable *Alimentación*

$$f_{\overline{AFIS}}(F) = \sum_{A \in \{e, \neg e\}} f_{AFIS}(A) = \begin{array}{c|c} F & \\ \hline S & 0.104 + 0.177 = 0.281 \\ n & 0.096 + 0.208 = 0.304 \end{array}$$

Y por último la variable *Deporte* ( $P(D = n)$ ) tiene el valor fijado a *no* y dado que no depende de la variable *fumador* se puede obviar, ya que es un factor constante.

Ahora, si normalizamos a 1

$$P(F|I = s, D = n) = \begin{array}{c|c} F & \\ \hline S & 0.48 \\ n & 0.52 \end{array}$$

## Complejidad de la inferencia exacta

- La complejidad del algoritmo de eliminación de variables depende del tamaño del mayor factor, que depende del orden en el que se evalúan las variables y la topología de la red
- El orden de evaluación que escogeremos será el topológico según el grafo
- La complejidad de la inferencia exacta es NP-hard en el caso general
- Si la red bayesiana cumple que para cada par de nodos hay un único camino no dirigido (**poliárbol**) entonces se puede calcular en tiempo lineal
- Para obtener resultados en el caso general se recurre a algoritmos aproximados basados en técnicas de muestreo

# Summary

- Bayesian networks provide a natural representation for (causally induced) conditional independence.
- Topology + CPTs = compact representation of joint distribution.
- Generally easy for domain experts to construct.