

Bases Formales de Computación

Redes de Bayes

Camilo Rueda ¹

¹Universidad Javeriana-Cali

PUJ 2008

Razonamiento bajo incertidumbre

Incetidumbre:

Cualidad o estado de ser no conocido con claridad

Razonar (probabilísticamente) bajo incertidumbre:

- razonar con conocimiento incompleto de **probabilidades**:
lógica probabilística
- idear representación de distribución probabilística completa de **historias** de estados:
redes de Bayes

Redes de Bayes

Razonamiento Bayesiano:

Inferencia probabilística basada en combinación de **información a priori** con **datos observados**

Redes de Bayes:

Lenguaje gráfico para especificar **distribuciones** probabilísticas complejas en razonamiento Bayesiano

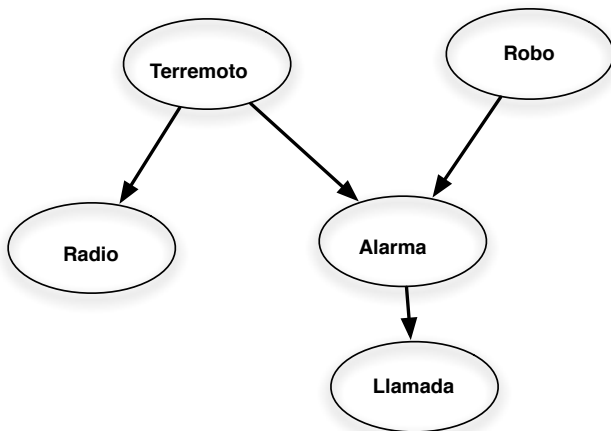
Redes de Bayes: un ejemplo

- Hay o no hay **robo** en la casa
(esto no depende de otras cosas en el modelo)
- Hay o no hay **terremoto**
(esto no depende de otras cosas en el modelo)
- La **alarma** puede dispararse por robo o por terremoto
- El vecino hace una **llamada** basado en si oye la alarma
- el reporte del **radio** depende de si hubo un terremoto

Cuáles son las relaciones causales?

Redes de Bayes: causalidad

Expresar **causalidad**



Notación

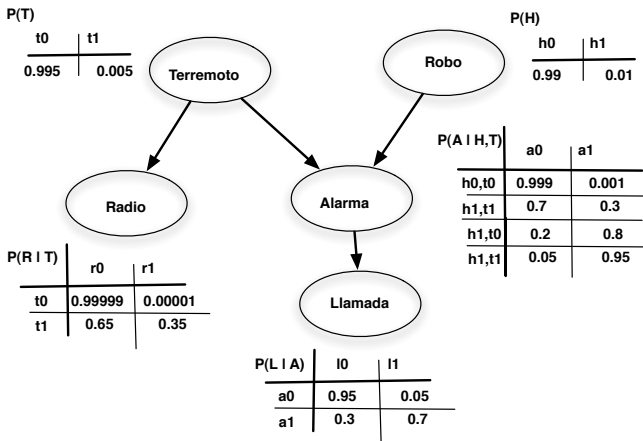
- “ Probabilidad de A dado que se conoce (con exactitud) B”:
 $P(A|B)$
- $P(X|Y)$: tabla 2-D con todos los valores:
 $P(X = x_i|Y = y_j)$
- Probabilidades condicionales pueden definirse en términos de probabilidades incondicionales:

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

- Por consiguiente la **regla de la cadena**:
 $P(X, Y) = P(X|Y)P(Y)$
- y **teorema de Bayes**:
 $P(X, Y) = P(X|Y)P(Y) = P(Y|X)P(X)$
 $P(X|Y) = P(Y|X)P(X)/P(Y)$

Especificar distribución de probabilidad en RB

- Probabilidades **a priori** de todo nodo raíz
- Probs **condicionales** de nodos internos, dada toda combinación de **predecesores directos**



Distribución conjunta

distribución **conjunta**:

distribución probabilística sobre todos los datos posibles

Si hay n variables, la DC requiere 2^n valores

Sean las variables: *gripa*(g), *alergia*(a), *sinusitis*(s),

g	a	s		0,027
g	a	\tilde{s}		0,003
g	\tilde{a}	s		0,162
g	\tilde{a}	\tilde{s}		0,108
\tilde{g}	a	s		0,014
\tilde{g}	a	\tilde{s}		0,056
\tilde{g}	\tilde{a}	s		0,0063
\tilde{g}	\tilde{a}	\tilde{s}		0,6237

Definición formal de Red de Bayes

una Red de Bayes $\mathcal{B} = (G, \theta)$ sobre X_1, \dots, X_n es un grafo G en el que:

- cada nodo X_i está asociado con una **tabla de probabilidad condicional** (TPC): $P(X_i, \text{Padres}(X_i))$
- TPC: distribución sobre X_i para cada combinación de valores de los **padres** de X_i
- \mathcal{B} representa la **distribución conjunta** sobre $X_1 \dots X_n$ mediante la **regla de la cadena** para RB:

$$P(x_1, \dots, x_n) = \prod_i P(x_i \mid \text{Padres}(X_i))$$

Cálculo de probabilidades a partir de DC

Sea la red de Bayes

$$G \rightarrow S \leftarrow A$$

y las TPC:

$$\begin{array}{cc|c}
 g & \left| \begin{array}{l} 0,3 \\ 0,7 \end{array} \right. & a & \left| \begin{array}{l} 0,1 \\ 0,9 \end{array} \right. & s & \left| \begin{array}{cccc} ga & g\tilde{a} & \tilde{g}a & \tilde{g}\tilde{a} \\ 0,9 & 0,6 & 0,2 & 0,01 \\ 0,1 & 0,4 & 0,8 & 0,99 \end{array} \right.
 \end{array}$$

entonces:

- $P(g, \tilde{a}, s) = P(g)P(\tilde{a})P(s | g, \tilde{a}) = 0,3 \times 0,9 \times 0,6 = 0,162$
- $P(\tilde{a} | s, g) = P(\tilde{a}, s, g) / P(s, g)$
 $P(s, g) = P(g, \tilde{a}, s) + P(g, a, s)$

Tipos de razonamiento

- **causal** (“hacia abajo”)
- de **diagnóstico** o evidencial (“hacia arriba”)
cuáles son las razones más probables de una observación
- **intercausal** (“explicar descarte de hipótesis”)

Tipos de razonamiento

- **causal** (“hacia abajo”)
 - probabilidad a priori de robo $P(h) = 0,01$
 - probabilidad a priori de terremoto $P(t) = 0,005$
 - probabilidad de que el vecino llame $P(l)$ es 0,0568
 - qué tan confiable es el vecino en detectar robos (i.e. $P(l | h)$) ?
- de **diagnóstico** o evidencial (“hacia arriba”)
cuáles son las razones más probables de una observación
- **intercausal** (“explicar descarte de hipótesis”)

Tipos de razonamiento

- **causal** (“hacia abajo”)
- de **diagnóstico** o evidencial (“hacia arriba”)
cuáles son las razones más probables de una observación
 - suponer que el vecino llama
 - la probabilidad de robo sube $P(h | I) = 0,325$
 - la probabilidad de terremoto también sube $P(t | I) = 0,1034$
- **intercausal** (“explicar descarte de hipótesis”)

Tipos de razonamiento

- **causal** (“hacia abajo”)
- de **diagnóstico** o evidencial (“hacia arriba”)
cuáles son las razones más probables de una observación
- **intercausal** (“explicar descarte de hipótesis”)
supongamos que el radio reporta terremoto.
Cómo afecta esto las creencias?
 - la probabilidad de terremoto sube sustancialmente
 $P(t | I, r) = 0,9993$
(mientras que $P(t | I) = 0,021$)
 - la probabilidad de robo **baja** $P(h | I, r) = 0,0268$

robo y terremoto son **independientes** pero
el reporte del radio **explica** la llamada

Reducción de parámetros en RB

Número de parámetros independientes para 5 variables es
 $2^5 - 1 = 31$

En la RB hay 10 parámetros independientes.
qué permite hacer esto?

Reducción de parámetros en RB

Número de parámetros independientes para 5 variables es
 $2^5 - 1 = 31$

En la RB hay 10 parámetros independientes.
qué permite hacer esto?

No **toda** distribución es representable en RB

Solo las que cumplen los **supuestos de independencia condicional**

La estructura de la RB permite identificar variables
condicionalmente independientes

Independencia condicional

Sean $\mathbf{X}, \mathbf{Y}, \mathbf{Z}$ conjuntos de variables y P una distribución.

\mathbf{X} es **independiente** de \mathbf{Y} dado \mathbf{Z} en P (escrito, $\mathcal{I}(\mathbf{X}, \mathbf{Y} | \mathbf{Z})$) si

para toda asignación de valores $\mathbf{x}, \mathbf{y}, \mathbf{z}$ a $\mathbf{X}, \mathbf{Y}, \mathbf{Z}$

$$P(\mathbf{x} | \mathbf{z}, \mathbf{y}) = P(\mathbf{x} | \mathbf{z})$$

o sea,

$$P(\mathbf{X} | \mathbf{Y}, \mathbf{Z}) = P(\mathbf{X} | \mathbf{Z})$$

$$P(\mathbf{X}, \mathbf{Y} | \mathbf{Z}) = P(\mathbf{X} | \mathbf{Z})P(\mathbf{Y} | \mathbf{Z})$$

Independencia condicional (2)

Cómo “fluye ” la influencia de variables en una RB?
Cuándo el observar el valor de X cambia nuestra creencia sobre el valor de Y ?

Independencia condicional (2)

Cómo “fluye ” la influencia de variables en una RB?
Cuándo el observar el valor de X cambia nuestra creencia sobre el valor de Y ?

- Caso obvio: cuando X es padre de Y y también cuando X es hijo de Y :

dos nodos **directamente** conectados están correlacionados

- cuando X es ancestro o descendiente de Y ?

Independencia condicional (2)

Cómo “fluye ” la influencia de variables en una RB?
Cuándo el observar el valor de X cambia nuestra creencia sobre el valor de Y ?

- Caso obvio: cuando X es padre de Y y también cuando X es hijo de Y :

dos nodos **directamente** conectados están correlacionados

- cuando X es ancestro o descendiente de Y ? si.
Cuando observamos robo, la probabilidad de alarma **sube** por consiguiente, también la de llamada

Independencia condicional: otros casos

si se dispara la alarma, la probabilidad de terremoto aumenta:

$$P(t \mid a) > P(t)$$

luego también sube la de reporte en el radio.

Independencia condicional: otros casos

Nodos en camino de un arco **hacia arriba** y luego **hacia abajo** están correlacionados

Independencia condicional: otros casos

Nodos en camino de un arco **hacia arriba** y luego **hacia abajo** están correlacionados

y en camino de uno hacia abajo y luego hacia arriba?
p.ej. observar robo, cambia la probabilidad de terremoto?

Independencia condicional: otros casos

Nodos en camino de un arco **hacia arriba** y luego **hacia abajo** están correlacionados

Nodos en camino en forma de V , **NO** están correlacionados.
 $\mathcal{I}(H, T \mid \emptyset)$

Independencia condicional: otros casos

si la alarma se dispara, la probabilidad de llamada aumenta:

$$(P(I | a) > P(I))$$

si además hubo un robo, cambia esto la probabilidad de llamada?

Independencia condicional: otros casos

si la alarma se dispara, la probabilidad de llamada aumenta:

$$(P(I | a) > P(I))$$

si además hubo un robo, cambia esto la probabilidad de llamada? no!

$$P(I | a, h) = P(I | a). \text{ O sea, } \mathcal{I}(H, L | A)$$

Independencia condicional: otros casos

Nodos en camino de dependencia, pero **con evidencia de nodos intermedios NO** están correlacionados
p.ej. H y L dado A , o también A y R dado T

Independencia condicional: otros casos

Los nodos T y H son independientes. Pero, si se sabe A ?

Independencia condicional: otros casos

Los nodos T y H son independientes. Pero, si se sabe A ? se vuelven dependientes!

Independencia condicional: otros casos

Nodos en camino de un arco **hacia arriba** y luego **hacia abajo** están correlacionados

Nodos en camino en forma de V , **NO** están correlacionados.
 $\mathcal{I}(H, T \mid \emptyset)$

Nodos en camino de dependencia, pero **con evidencia de nodos intermedios NO** están correlacionados
p.ej. H y L dado A , o también A y R dado T

Nodos en camino en V , pero **con evidencia de nodos intermedios** (o de sucesores) **se vuelven** correlacionados

Camino activo: definición general

Un camino X_1, \dots, X_n es **activo** dado \mathbf{Z} si

- cuando existe el camino $X_{i-1} \rightarrow X_i \leftarrow X_{i+1}$, entonces X_i o uno de sus descendientes está en \mathbf{Z}
- ningún otro nodo en el camino está en \mathbf{Z}

Dos nodos X, Y están **d -separados** dado \mathbf{Z} si no hay caminos activos entre ellos.

Cuando X, Y están d -separados dado \mathbf{Z} entonces $\mathcal{I}(X, Y \mid \mathbf{Z})$

Inferencia en RB

- $A \rightarrow B$:

$$P(B) = P(a)P(B | a) + P(\tilde{a})P(B | \tilde{a})$$

$$\text{en general: } P(B) = \sum_A P(A)P(B | A)$$

(componentes en TPC)

- $A \rightarrow B \rightarrow C$:

$$P(c) = \sum_b P(b)P(c | b) \quad (\text{v\u00e1lido ssi } \mathcal{I}(A, C | B))$$

(componentes en TPC o ya calculados)

- generalizable a cualquier cadena

Complejidad para n variables y tablas de k valores: $O(nk^2)$

Algoritmo de Inferencia en RB: la idea

Por qué no es necesario calcular toda probabilidad conjunta?


$$\begin{aligned}p(d) &= \sum_{a,b,c} P(a, b, c, d) \\&= \sum_{a,b,c} P(a)P(b | a)P(c | b)P(d | c) \\&= \sum_a \sum_b \sum_c P(a)P(b | a)P(c | b)P(d | c) \\&= \sum_c \sum_b \sum_a P(a)P(b | a)P(c | b)P(d | c) \\&= \sum_c P(d | c) \sum_b P(c | b) \sum_a P(a)P(b | a)\end{aligned}$$

Algoritmo de Inferencia en RB: la idea (2)

Calcular “factores” sucesivamente

$f_A(b) = \sum_a P(a)P(b | a)$ que corresponde a $P(B)$

luego $f_B(c) = \sum_b f_A(b)P(c | b)$, etc. (**programación dinámica**)



$$P(m) = \sum_{l,r,c} P(m | l, r) P(l | c) P(r | c) P(c)$$

$$= \sum_{l,r} P(m | l, r) \sum_c P(l | c) P(r | c) P(c)$$

definimos $f_C(l, r) = \sum_c P(l | c) P(r | c) P(c)$ y luego,
 $\sum_{l,r} P(m | l, r) f_1(l, r)$

Algoritmo de Inferencia en RB: eliminación de variables

- el algoritmo opera sobre **factores** o tablas
- **factor** f sobre Y_1, \dots, Y_n : función $f(Y_1, \dots, Y_n) \in \mathbb{R}$
- factores pueden sumarse y multiplicarse

Algoritmo de Inferencia en RB: eliminación de variables

- el algoritmo opera sobre **factores** o tablas
- **factor** f sobre Y_1, \dots, Y_n : función $f(Y_1, \dots, Y_n) \in \mathbb{R}$
ejemplo:
 - una DC $P(H, T, A, R, L)$ es factor sobre H, T, A, R, L
 - una TPC $P(A | H, T)$ es factor sobre H, T
- factores pueden sumarse y multiplicarse

Algoritmo de Inferencia en RB: eliminación de variables

- el algoritmo opera sobre **factores** o tablas
- **factor** f sobre Y_1, \dots, Y_n : función $f(Y_1, \dots, Y_n) \in \mathbb{R}$
ejemplo:
 - una DC $P(H, T, A, R, L)$ es factor sobre H, T, A, R, L
 - una TPC $P(A | H, T)$ es factor sobre H, T
- factores pueden sumarse y multiplicarse
 - $f'(C, L, R) = f_1(C) \times f_2(L, C) \times f_3(R, C)$
equivalente a $P(C, L, R) = P(C)P(L | C)P(R | C)$
 - $f''(L, R) = \sum_C f'(C, L, R)$
equivalente a $P(l, r) = \sum_c P(c, l, r)$

Algoritmo de eliminación de variables

procedure eliminar-variables(

 Grafo sobre X_1, \dots, X_n , // estructura de la RB

$P(X_i \mid \text{padres}(X_i))$, // TPC de nodos RB

Y_1, \dots, Y_k // variables de query

)

 Sea \mathcal{F} el conjunto de factores $\{P(X_i \mid \text{padres}(X_i)) : i = 1 \dots n\}$

 Sea $\{Z_1, \dots, Z_m\} = \mathbf{X} - \mathbf{Y}$

 para $i = 1, \dots, m$

 Extraiga de \mathcal{F} todo factor f_1, \dots, f_r que mencione a Z_i

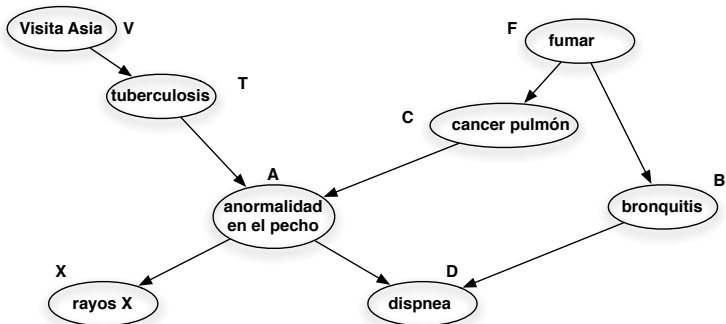
 Sea $f' = \prod_j f_j$

 sea $f'' = \sum_{Z_i} f'$

 Inserte f'' en \mathcal{F}

 retorne($\prod_{f \in \mathcal{F}} f$)

Algoritmo: un ejemplo



Algoritmo: un ejemplo (2)

calcular

$$P(D) = \sum_{A,B,C,T,F,X,V} P(V)P(T | V)P(F)P(C | F) \\ P(B | F)P(A | P, T)P(X | A) \\ P(D | A, B)$$

- eliminar V : $f_V(T) = \sum_V P(T | V)P(V)$
- eliminar F : $f_F(B, C) = \sum_F P(B | F)P(C | F)P(F)$
- eliminar X : $\sum_X P(X | A)$
- calcular probabilidad de C : $f_B(C) = \sum_B f_F(B, C)$
- eliminar T : $f_T(A, C) = \sum_T P(A | T, C)f_V(T)f_B(C)$
- eliminar C : $f_P(A, B) = \sum_C f_F(B, C) \times f_T(A, C)$
- eliminar A, B : $\sum_{A,B} P(D | A, B)f_P(A, B)$