

Introducción a las Redes Bayesianas


Redes bayesianas

- Como vimos en el tema anterior, las relaciones de independencia (condicional) nos permiten reducir el tamaño de la información necesaria para especificar una DCC
 - Las redes bayesianas (o redes de creencia) constituyen una manera práctica y compacta de representar el conocimiento incierto, basada en esta idea
- **Una red bayesiana es un grafo dirigido acíclico** que consta de:
 - Un conjunto de nodos, uno por cada variable aleatoria del “mundo”
 - Un conjunto de arcos dirigidos que conectan los nodos; si hay un arco de X a Y decimos que X es un *padre* de Y ($padres(X)$ denota el conjunto de v.a. que son padres de X)
 - Cada nodo X_i contiene la distribución de probabilidad condicional $P(X_i|padres(X_i))$
- Intuitivamente, en una red bayesiana una arco entre X e Y significa *una influencia directa* de X sobre Y
 - Es tarea del experto en el dominio el decidir las relaciones de dependencia directa (es decir, la *topología* de la red)

Ejemplo de red bayesiana (Russell y Norvig)

$P(sol)$	$P(lluv)$	$P(nubl)$	$P(nieve)$
0.7	0.2	0.08	0.02

$P(caries)$
0.8



Caries	$P(dolor)$
<i>caries</i>	0.6
<i>no caries</i>	0.1

Caries	$P(hueco)$
<i>caries</i>	0.9
<i>no caries</i>	0.2

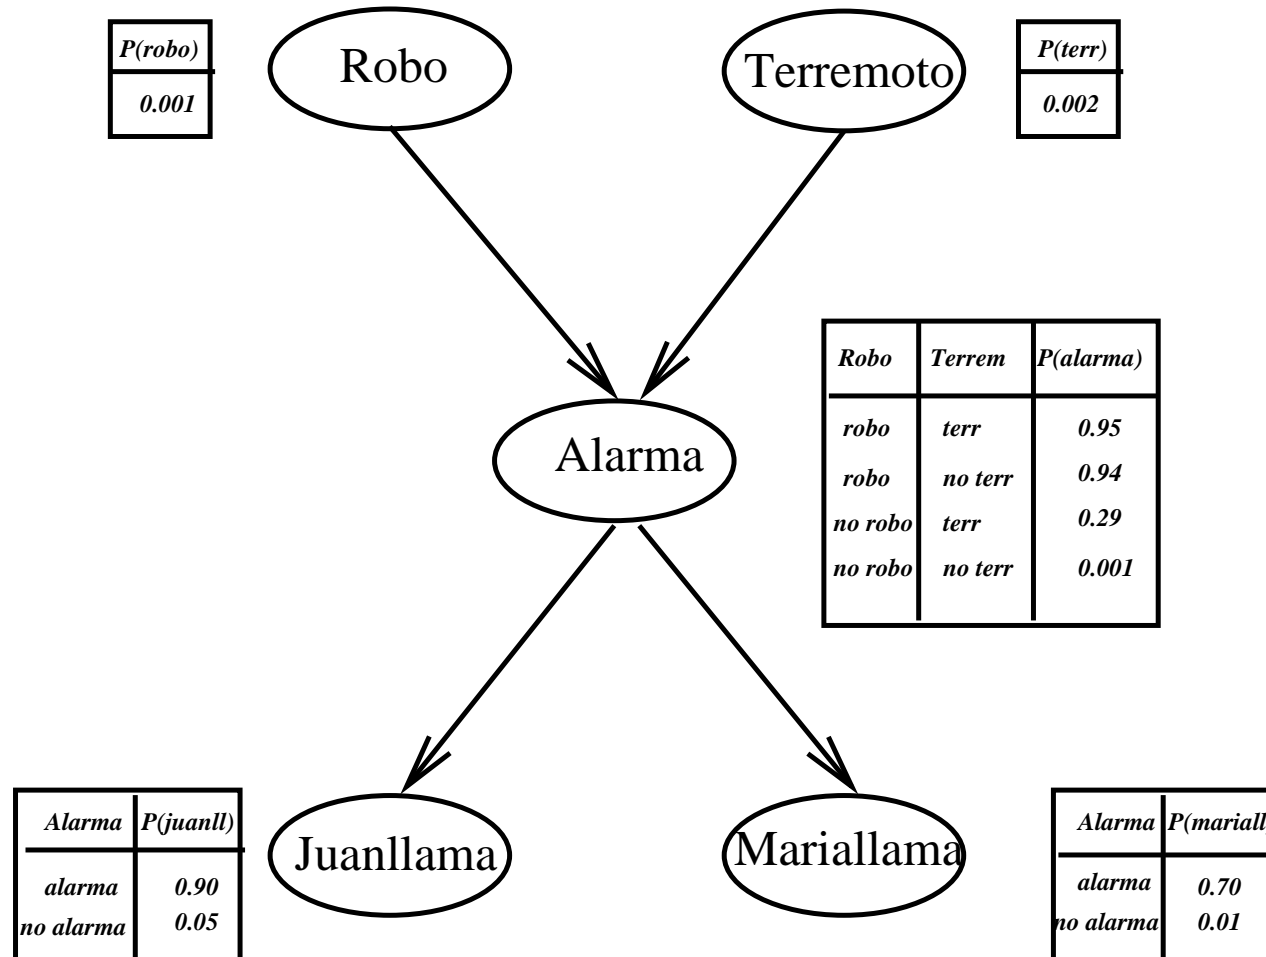
Observaciones sobre el ejemplo

- La topología de la red anterior nos expresa que:
 - *Caries* es una *causa directa* de *Dolor* y *Huecos*
 - *Dolor* y *Huecos* son condicionalmente independientes dada *Caries*
 - *Tiempo* es independiente de las restantes variables
- No es necesario dar la probabilidad de las negaciones de *caries*, *dolor*,
...

Otro ejemplo (Pearl, 1990):

- Tenemos una alarma antirrobo instalada en una casa
 - La alarma salta normalmente con la presencia de ladrones
 - Pero también cuando ocurren pequeños temblores de tierra
- Tenemos dos vecinos en la casa, Juan y María, que han prometido llamar a la policía si oyen la alarma
 - Juan y María podrían no llamar aunque la alarma sonara: por tener música muy alta en su casa, por ejemplo
 - Incluso podrían llamar aunque no hubiera sonado: por confundirla con un teléfono, por ejemplo

Red bayesiana para el ejemplo de la alarma



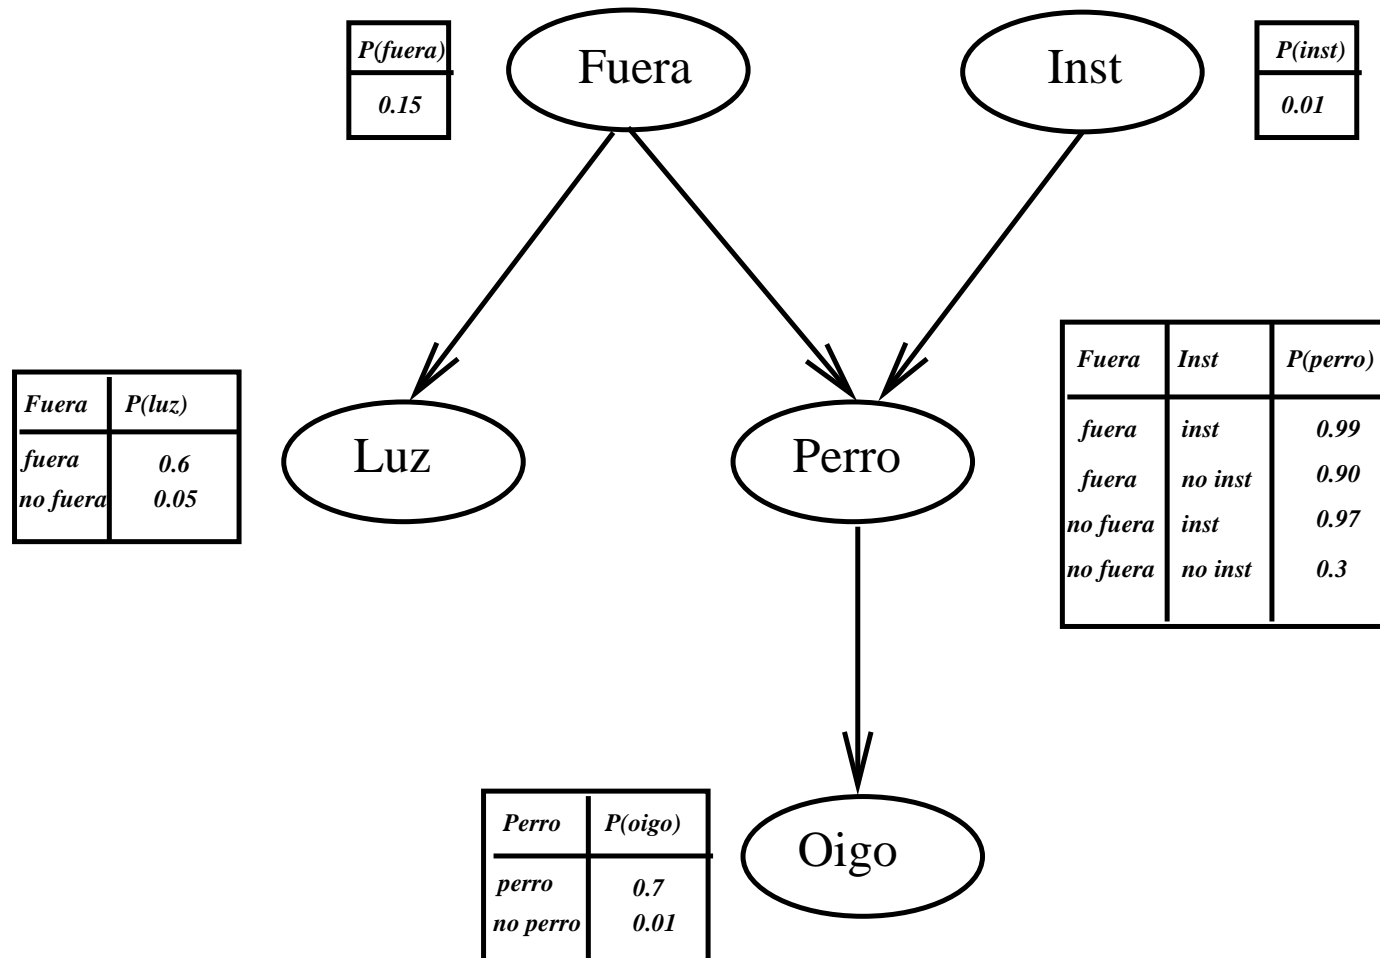
Observaciones sobre el ejemplo

- La topología de la red nos expresa que:
 - *Robo* y *Terremoto* son causas directas para *Alarma*
 - También, *Robo* y *Terremoto* son causas para *Juanllama* y para *Mariallama*, pero esa influencia sólo se produce a través de *Alarma*: ni Juan ni María detectan directamente el robo ni los pequeños temblores de tierra
 - En la red no se hace referencia directa, por ejemplo, a las causas por las cuales María podría no oír la alarma: éstas están implícitas en la tabla de probabilidades $P(\text{Mariallama}|\text{Alarma})$

Un tercer ejemplo (Charniak, 1991):

- Supongamos que quiero saber si alguien de mi familia está en casa, basándome en la siguiente información
 - Si mi esposa sale de casa, usualmente (pero no siempre) enciende la luz de la entrada
 - Hay otras ocasiones en las que también enciende la luz de la entrada
 - Si no hay nadie en casa, el perro está fuera
 - Si el perro tiene problemas intestinales, también se deja fuera
 - Si el perro está fuera, oigo sus ladridos
 - Podría oír ladridos y pensar que son de mi perro aunque no fuera así
- Variables aleatorias (booleanas) en este problema:
 - *Fuera* (nadie en casa), *Luz* (luz en la entrada), *Perro* (perro fuera), *Inst* (problemas intestinales en el perro) y *Oigo* (oigo al perro ladrar)

Red bayesiana para el ejemplo de la familia fuera de casa



Las redes bayesianas representan DCCs

- Consideremos una red bayesiana con n variables aleatorias
 - Y un orden entre esas variables: X_1, \dots, X_n
- En lo que sigue, supondremos que:
 - $padres(X_i) \subseteq \{X_{i-1}, \dots, X_1\}$ (para esto, basta que el orden escogido sea consistente con el orden parcial que induce el grafo)
 - $P(X_i | X_{i-1}, \dots, X_1) = P(X_i | padres(X_i))$ (es decir, cada variable es condicionalmente independiente de sus anteriores, dados sus padres en la red)
- Estas condiciones expresan formalmente nuestra intuición al representar nuestro “mundo” mediante la red bayesiana correspondiente
 - En el ejemplo de la alarma, la red expresa que creemos que $P(Mariallama | Juanllama, Alarma, Terremoto, Robo) = P(Mariallama | Alarma)$

Las redes bayesianas representan DCCs

- En las anteriores condiciones, y aplicando repetidamente la regla del producto:

$$\begin{aligned} P(X_1, \dots, X_n) &= P(X_n | X_{n-1} \dots, X_1) P(X_{n-1} \dots, X_1) = \dots \\ &\dots = \prod_{i=1}^n P(X_i | X_{i-1}, \dots, X_1) = \prod_{i=1}^n P(X_i | \text{padres}(X_i)) \end{aligned}$$

- Es decir, una red bayesiana *representa una DCC* obtenida mediante la expresión $P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | \text{padres}(X_i))$
 - Por ejemplo, en el ejemplo de la alarma, la probabilidad de que la alarma suene, Juan y María llamen a la policía, pero no haya ocurrido nada es (usamos iniciales, por simplificar) :

$$\begin{aligned} P(j, m, a, \neg r, \neg t) &= P(j|a)P(m|a)P(a|\neg r, \neg t)P(\neg r)P(\neg t) = \\ &= 0,9 \times 0,7 \times 0,001 \times 0,999 \times 0,998 = 0,00062 \end{aligned}$$

Representaciones compactas

- Dominios *localmente estructurados*:
 - Las relaciones de independencia que existen entre las variables de un dominio hacen que las redes bayesianas sean una representación mucho más compacta y eficiente de una DCC que la tabla con todas las posibles combinaciones de valores
 - Además, para un experto en un dominio de conocimiento suele ser más natural dar probabilidades condicionales que directamente las probabilidades de la DCC
 - Con n variables, si cada variable está directamente influenciada por k variables a lo sumo, entonces una red bayesiana necesitaría $n2^k$ números, frente a los 2^n números de la DCC
 - Por ejemplo, Para $n = 30$ y $k = 5$, esto supone 960 números frente a 2^{30} (billones)
- Hay veces que una variable influye directamente sobre otra, pero esta dependencia es muy tenue
 - En ese caso, puede compensar no considerar esa dependencia, perdiendo algo de precisión en la representación, pero ganado manejabilidad

Algoritmo de construcción de una red bayesiana

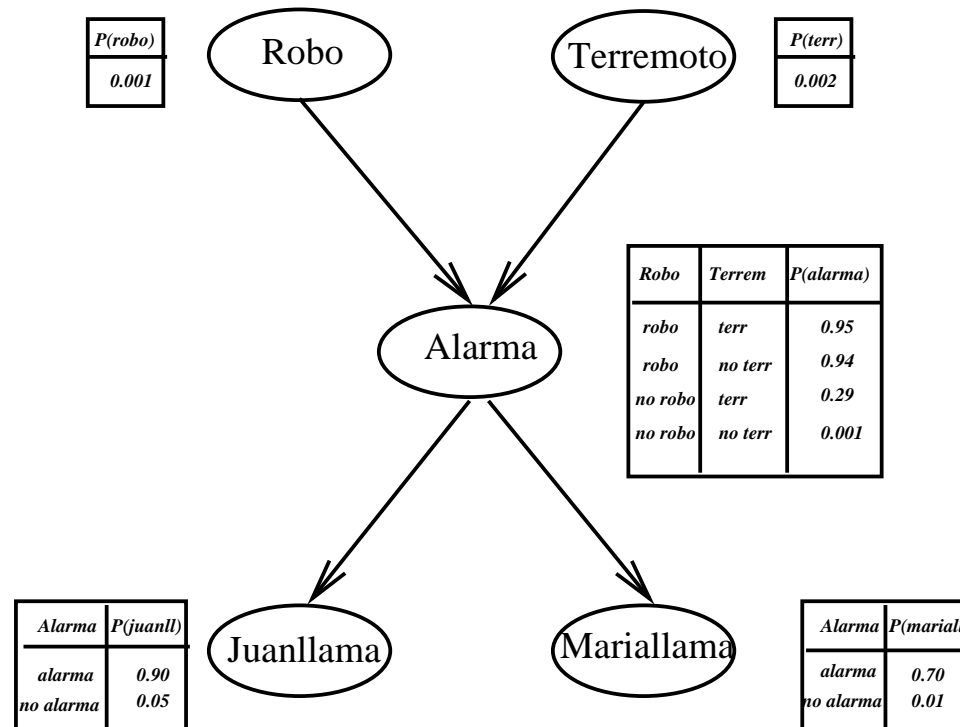
- Supongamos dado un conjunto de variables aleatorias VARIABLES que representan un dominio de conocimiento (con incertidumbre)

FUNCION CONSTRUYE_RED(VARIABLES)

1. Sea (X_1, \dots, X_n) una ordenación de las variables de VARIABLES
2. Sea RED una red bayesiana ‘vacía’
3. PARA $i=1, \dots, n$ HACER
 - 3.1 Añadir un nodo etiquetado con X_i a RED
 - 3.2 Sea $\text{padres}(X_i)$ un subconjunto minimal de $\{X_{i-1}, \dots, X_1\}$ tal que existe una independencia condicional entre X_i y cada elemento de $\{X_{i-1}, \dots, X_1\}$ dado $\text{padres}(X_i)$
 - 3.3 Añadir en RED un arco dirigido entre cada elemento de $\text{padres}(X_i)$ y X_i
 - 3.4 Asignar al nodo X_i la tabla de probabilidad $P(X_i | \text{padres}(X_i))$
4. Devolver RED

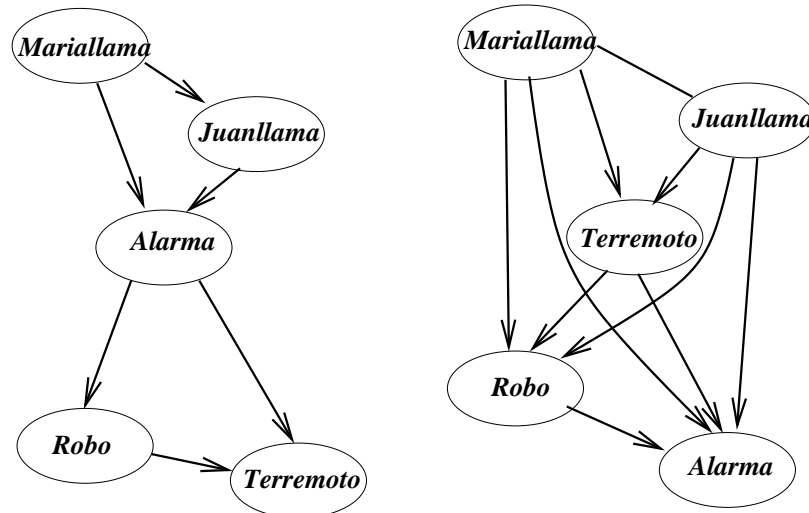
Ejemplo de construcción de red bayesiana (alarma)

- Partiendo del orden *Robo*, *Terremoto*, *Alarma*, *Juanllama*, *Mariallama*, y aplicando el algoritmo anterior obtenemos la red del ejemplo:



Construcción de redes bayesianas

- Problema: elección del orden entre variables
 - En general, deberíamos empezar por las “causas originales”, siguiendo con aquellas a las que influyen directamente, etc..., hasta llegar a las que no influyen directamente sobre ninguna (modelo *causal*)
 - Esto hará que las tablas reflejen probabilidades “causales” más que “diagnósticos”, lo cual suele ser preferible por los expertos
- Un orden malo puede llevar a representaciones poco eficientes
 - Red izquierda (*Mariallama*, *Juanllama*, *Alarma*, *Robo* y *Terremoto*); red derecha (*Mariallama*, *Juanllama*, *Terremoto*, *Robo* y *Alarma*)



Inferencia probabilística en una red bayesiana

- El problema de la inferencia en una red bayesiana
 - Calcular la probabilidad a posteriori para un conjunto de *variables de consulta*, dado que se han observado algunos valores para las *variables de evidencia*
 - Por ejemplo, podríamos querer saber qué probabilidad hay de que realmente se haya producido un robo, sabiendo que tanto Juan como María han llamado a la policía
 - Es decir, calcular $P(\text{Robo} | \text{juanllama}, \text{mariallama})$
- Notación:
 - X denotará la variable de consulta (sin pérdida de generalidad supondremos sólo una variable)
 - E denota un conjunto de *variables de evidencia* E_1, E_2, \dots, E_n y e una observación concreta para esas variables
 - Y denota al conjunto de las restantes variables de la red (variables *ocultas*) e y representa un conjunto cualquiera de valores para esas variables

Inferencia por enumeración

- Recordar la fórmula para la inferencia probabilística a partir de una DCC:

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

- Esta fórmula será la base para la inferencia probabilística:
 - Puesto que una red bayesiana es una representación de una DCC, nos permite calcular cualquier probabilidad a posteriori a partir de la información de la red bayesiana
 - Esencialmente, se trata de una suma de productos de los elementos de las distribuciones condicionales

Un ejemplo de inferencia probabilística

- Ejemplo de la alarma (usamos iniciales por simplificar)

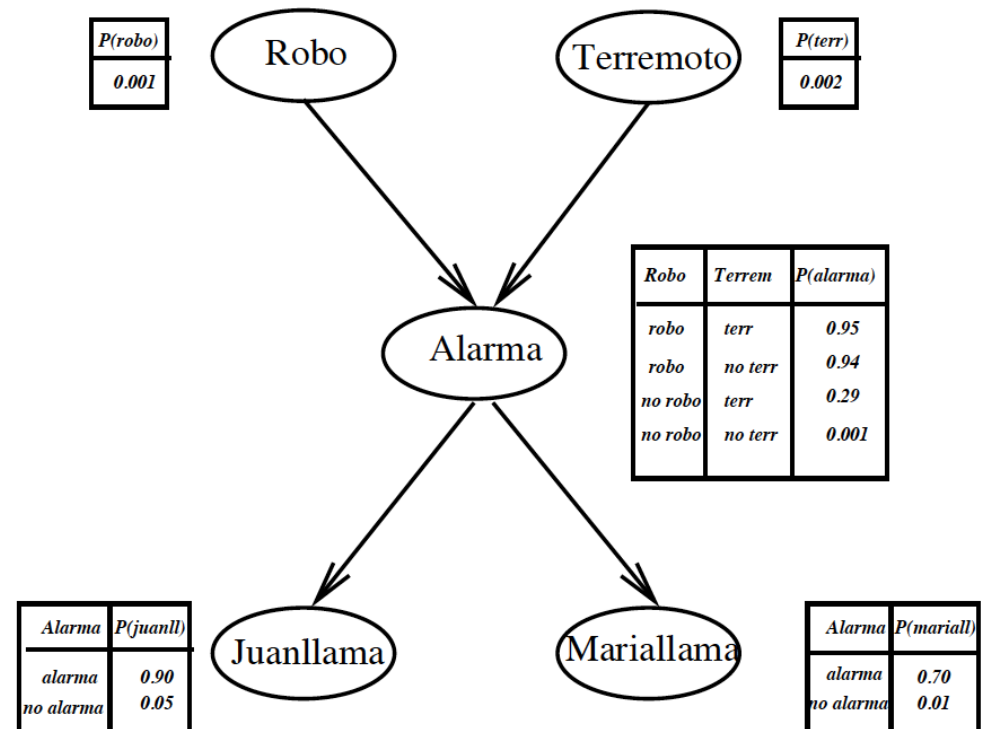

$$\begin{aligned} P(R|j, m) &= \langle P(r|j, m), P(\neg r|j, m) \rangle = \alpha \langle \sum_t \sum_a P(r, t, a, j, m), \sum_t \sum_a P(\neg r, t, a, j, m) \rangle = \\ &= \alpha \langle \sum_t \sum_a P(r)P(t)P(a|r, t)P(j|a)P(m|a), \sum_t \sum_a P(\neg r)P(t)P(a|\neg r, t)P(j|a)P(m|a) \rangle \end{aligned}$$

- En este ejemplo hay que hacer 2×4 sumas, cada una de ellas con un producto de cinco números tomados de la red bayesiana
 - En el peor de los casos, con n variables booleanas, este cálculo toma $O(n2^n)$
- Una primera mejora consiste en sacar factor común de aquellas probabilidades que sólo involucran variables que no aparecen en el sumatorio:

$$\begin{aligned} P(R|j, m) &= \alpha \langle P(r) \sum_t P(t) \sum_a P(a|r, t)P(j|a)P(m|a), P(\neg r) \sum_t P(t) \sum_a P(a|\neg r, t)P(j|a)P(m|a) \rangle = \\ &= \alpha \langle 0,00059224, 0,0014919 \rangle = \langle 0,284, 0,716 \rangle \end{aligned}$$

Inferencia por enumeración

- Las operaciones realizadas en la fórmula anterior se pueden simbolizar con el siguiente árbol



Algoritmo de inferencia por enumeración

- **Entrada:** una v.a. X de consulta, un conjunto de valores observados e para la variables de evidencia y una red bayesiana. **Salida:** $P(X|e)$

FUNCION INFERENCIA_ENUMERACION(X, e, RED)

1. Sea $Q(X)$ una distribución de probabilidad sobre X , inicialmente vacía
2. PARA cada valor x_i de X HACER
 - 2.1 Extender e con el valor x_i para X
 - 2.2 Hacer $Q(x_i)$ el resultado de $ENUM_AUX(VARIABLES(RED), e, RED)$
3. Devolver $NORMALIZA(Q(X))$

FUNCION ENUM_AUX(VARS, e, RED)

1. Si VARS es vacío devolver 1
2. Si no,
 - 2.1 Hacer Y igual a PRIMERO(VARS)
 - 2.2 Si Y tiene un valor y en e devolver $P(y|\text{padres}(Y, e)) \cdot ENUM_AUX(RESTO(VARS), e)$
Si no, devolver $SUMATORIO(y, P(y|\text{padres}(Y, e)) \cdot ENUM_AUX(RESTO(VARS), e_y))$
(donde: $\text{padres}(Y, e)$ es el conjunto de valores que toman en e
los padres de Y en la RED , y e_y extiende e con el valor y para Y)

Algoritmo de inferencia por enumeración

- Observación:
 - Para que el algoritmo funcione, $VARIABLES(RED)$ debe devolver las variables en un orden consistente con el orden implícito en el grafo de la red (de arriba hacia abajo)
- Recorrido en profundidad:
 - El algoritmo genera el árbol de operaciones anterior de arriba hacia abajo, en profundidad
 - Por tanto, tiene un coste lineal en espacio
- Puede realizar cálculos repetidos
 - En el ejemplo, $P(j|a)P(m|a)$ y $P(j|\neg a)P(m|\neg a)$ se calculan dos veces
 - Cuando hay muchas variables, estos cálculos redundantes son inaceptables en la práctica

Evitando cálculos redundantes

- Idea para evitar el cálculo redundante:
 - Realizar las operaciones *de derecha a izquierda* (o, equivalentemente, de abajo a arriba en el árbol de operaciones)
 - Almacenar los cálculos realizados para posteriores usos
- En lugar de multiplicar *números*, multiplicaremos *tablas de probabilidades*
 - Denominaremos *factores* a estas tablas
 - Por ejemplo, la operación $P(R|j, m) = \alpha P(R) \sum_t P(t) \sum_a P(a|R, t) P(j|a) P(m|a)$ puede verse como la *multiplicación* de cinco tablas o *factores* en los que hay intercaladas dos operaciones de suma o *agrupamiento*
 - Se trata de hacer esas operaciones entre factores de derecha a izquierda
 - Es el denominado algoritmo de *eliminación de variables*
 - Veamos con más detalle cómo actuaría este algoritmo para calcular $P(R|j, m)$

El algoritmo de eliminación de variables: un ejemplo

- En primer lugar, tomamos un orden fijado entre las variables de la red
 - Un orden adecuado será esencial para la eficiencia del algoritmo (más adelante comentaremos algo más sobre el orden)
 - En nuestro caso, tomaremos el inverso de un orden consistente con la topología de la red: M, J, A, T, R
- El factor correspondiente a M se obtiene a partir de la distribución condicional $P(M|A)$
 - Como M es una variable de evidencia y su valor está fijado a *true*, el factor correspondiente a $P(m|A)$, que notamos $f(A)$, es la tabla con componentes $P(m|a)$ y $P(m|\neg a)$:

A		$f_1(A)$
T		0.70
F		0.01

El algoritmo de eliminación de variables: un ejemplo

- La siguiente variable en el orden es J
 - De manera análoga $f_2(A)$ (tomado de $P(j|A)$) es el factor correspondiente
- Siguiendo variable: A
 - El factor correspondiente, notado $f_3(A, R, T)$ se obtiene a partir de $P(A|R, T)$
 - Ninguna de esas variables es de evidencia, y por tanto no están fijados sus valores
 - Es una tabla con $2 \times 2 \times 2$, una por cada combinación de valores de R (variable de consulta) A y T (variables ocultas)
 - En este caso, esta tabla está directamente en la propia red

El algoritmo de eliminación de variables: un ejemplo

- Hasta ahora, no hemos realizado ninguna operación
 - Sólomente hemos construido los factores
- Pero A es una variable oculta, así que hemos de realizar el sumatorio sobre sus valores
 - Por tanto, multiplicamos ahora los tres factores y sumamos sobre A
 - La multiplicación de f_1 , f_2 y f_3 , notada $f_4(A, R, T)$ se obtiene multiplicando las entradas correspondientes a los mismos valores de A , R y T
 - Es decir, para cada valor v_1 de A , v_2 de R y v_3 de T se tiene $f_4(v_1, v_2, v_3) = f_1(v_1)f_2(v_1)f_3(v_1, v_2, v_3)$
 - Por ejemplo: $f_4(true, false, true) = f_1(true)f_2(true)f_3(true, false, true) = 0,70 \times 0,90 \times 0,29 = 0,1827$
 - Almacenamos f_4 y nos olvidamos de f_1 , f_2 y f_3
 - Nota: aunque no es éste el caso, si alguno de los factores no tuviera a la variable A como argumento, lo conservaríamos y no participaría en la multiplicación, ni en el agrupamiento posterior

El algoritmo de eliminación de variables: un ejemplo

- Ahora hay que *agrupar* el valor de A en f_4 (realizar el sumatorio \sum_a)
 - Así, obtenemos una tabla $f_5(R, T)$ haciendo $f_5(v_1, v_2) = \sum_a f_4(a, v_1, v_2)$ para cada valor v_1 de R y v_2 de T , y variando a en los posibles valores de A
 - Llamaremos a esta operación *agrupamiento*
 - Hemos *eliminado* la variable A
 - Una vez realizada la agrupación, guardamos f_5 y nos olvidamos de f_4
- Continuamos con la siguiente variable T :
 - El factor correspondiente a esta variable, que notaremos $f_6(T)$, es la tabla $P(T)$
- T es una variable oculta
 - Por tanto, debemos multiplicar y agrupar, eliminando la variable T
 - Notemos por $f_7(R)$ al resultado de multiplicar f_6 por f_5 y agrupar por T
 - Podemos olvidarnos de f_5 y f_6

El algoritmo de eliminación de variables: un ejemplo

- Última variable: R
 - El factor correspondiente a esta variable, que notaremos $f_8(R)$, es la tabla $P(R)$
- Para finalizar:
 - Multiplicamos los factores que nos quedan (f_7 y f_8) para obtener $f_9(R)$ y normalizamos para que sus dos entradas sumen 1
 - La tabla finalmente devuelta es justamente la distribución $P(R|j.m)$

Observaciones sobre el algoritmo de eliminación de variables

- En cada momento tenemos un conjunto de factores, que va cambiando:
 - Al añadir un nuevo factor, uno por cada variable que se considera
 - Al multiplicar factores
 - Al agrupar por una variable oculta
- Multiplicación de tablas:
 - Si $f_1(X, Y)$ y $f_2(Y, Z)$ son dos tablas cuyas variables en común son las de Y , se define su producto $f(X, Y, Z)$ como la tabla cuyas entradas son $f(x, y, z) = f_1(x, y)f_2(y, z)$
 - Similar a una operación *join* en bases de datos, multiplicando los valores correspondientes
- En el algoritmo de eliminación de variables, sólo multiplicaremos tablas:
 - Previo a realizar cada operación de agrupamiento
 - Y en el paso final

Observaciones sobre el algoritmo de eliminación de variables

- Agrupamiento de tablas:
 - Dado *un conjunto de factores*, la operación de agrupar (respecto de los valores de una v.a. X) consiste en obtener *otro conjunto de factores*
 - Se dejan igual aquellos que no tienen a la variable X entre sus argumentos
 - Y el resto de factores se multiplican y *se sustituyen* por el resultado multiplicarlos y sumar en la tabla por cada posible valor de X
 - Por ejemplo, si en el conjunto de factores $f_1(T)$, $f_2(A, R, T)$, $f_3(A)$, $f_4(A)$ tuvierámos que agrupar por la variable T , dejamos f_3 y f_4 y sustituimos f_1 y f_2 por el resultado de agregar (por cada valor de T) la multiplicación de f_1 y f_2
 - La operación de sumar por un valor es similar a la *agregación* de una columna en bases de datos

Un paso previo de optimización: variables irrelevantes

- En el algoritmo de eliminación de variables, se suele realizar un paso previo de eliminación de variables irrelevantes para la consulta
- Ejemplo:
 - Si la consulta a la red del ejemplo es $P(J|r)$, hay que calcular $\alpha P(r) \sum_t P(t) \sum_a P(a|r, t) P(J|a) \sum_m P(m|a)$
 - Pero $\sum_m P(m|a) = 1$, así que la variable M es irrelevante para la consulta
 - Siempre podemos eliminar cualquier variable que sea una hoja de la red y que no sea de consulta ni de evidencia
 - Y en general, se puede demostrar que toda variable que no sea antecesor (en la red) de alguna de las variables de consulta o de evidencia, es irrelevante para la consulta y por tanto *puede ser eliminada*

El algoritmo de eliminación de variables

- Entrada: una v.a. X de consulta, un conjunto de valores observados e para la variables de evidencia y una red bayesiana. Salida: $P(X|e)$

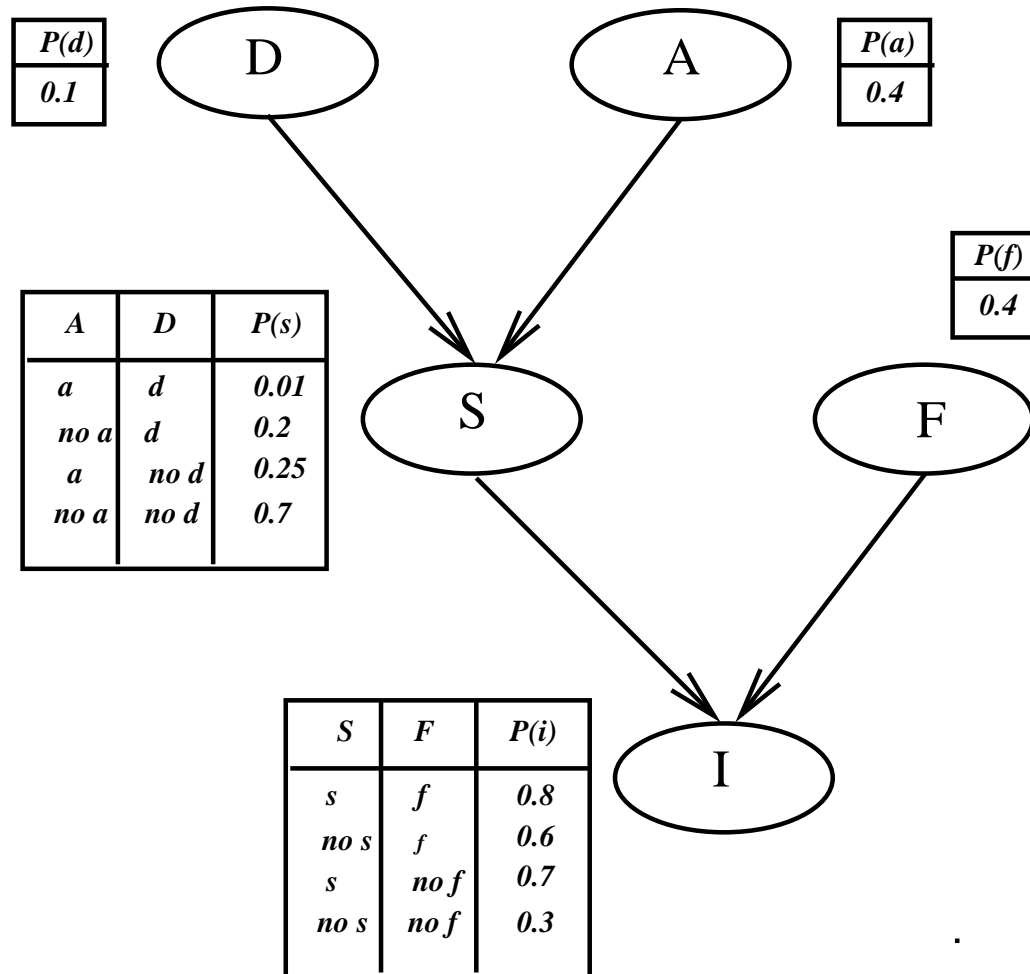
FUNCION INFERENCIA_ELIMINACION_VARIABLEES(X, e, RED)

1. Sea RED_E el resultado de eliminar de RED las variables irrelevantes para la consulta realizada
2. Sea $FACTORES$ igual a vacío
3. Sea $VARIABLES$ el conjunto de variables de RED_E
4. Sea VAR_ORD el conjunto de $VARIABLES$ ordenado según un orden de eliminación
5. PARA cada V en VAR_ORD HACER
 - 5.1 Sea $FACTOR$ el factor correspondiente a VAR (respecto de e)
 - 5.2 Añadir $FACTOR$ a $FACTORES$
 - 5.3 Si VAR es una variable oculta hacer $FACTORES$ igual a $AGRUPA(VAR, FACTORES)$
6. Devolver $NORMALIZA(MULTIPLICA(FACTORES))$

Otro ejemplo (Béjar)

- Consideremos las siguientes variables aleatorias:
 - D : práctica deportiva habitual
 - A : alimentación equilibrada
 - S : presión sanguínea alta
 - F : fumador
 - I : ha sufrido un infarto de miocardio
- Las relaciones causales y el conocimiento probabilístico asociado están reflejadas en la siguiente red bayesiana

Otro ejemplo: red bayesiana



Ejemplo de inferencia probabilística

- Podemos usar la red bayesiana para calcular la probabilidad de ser fumador si se ha sufrido un infarto y no se hace deporte, $P(F|i, \neg d)$

- Directamente:

- Aplicamos la fórmula: $P(F|i, \neg d) = \alpha P(F, i, \neg d) = \alpha \sum_{S,A} P(F, i, \neg d, A, S)$

- Factorizamos según la red: $P(F|i, \neg d) = \alpha \sum_{S,A} P(\neg d)P(A)P(S|\neg d, A)P(F)P(i|S, F)$

- Sacamos factor común: $P(F|i, \neg d) = \alpha P(\neg d)P(F) \sum_A P(A) \sum_S P(S|\neg d, A)P(i|S, F)$

- Calculemos:

- Para $F = true$:

$$\begin{aligned} P(f|i, \neg d) &= \alpha \cdot P(\neg d) \cdot P(f) [P(a) \cdot (P(s|\neg d, a) \cdot P(i|s, f) + P(\neg s|\neg d, a) \cdot P(i|\neg s, f)) + \\ &\quad + P(\neg a) \cdot (P(s|\neg d, \neg a) \cdot P(i|s, f) + P(\neg s|\neg d, \neg a) \cdot P(i|\neg s, f))] = \\ &= \alpha \cdot 0,9 \cdot 0,4 \cdot [0,4 \cdot (0,25 \cdot 0,8 + 0,75 \cdot 0,6) + 0,6 \cdot (0,7 \cdot 0,8 + 0,3 \cdot 0,6)] = \alpha \cdot 0,253 \end{aligned}$$

- Análogamente, para $F = false$, $P(\neg f|i, \neg d) = \alpha \cdot 0,274$

- Normalizando, $P(F|i, \neg d) = \langle 0,48, 0,52 \rangle$

Aplicando eliminación de variables

- Seguiremos el siguiente orden de variables, inspirado en la topología de la red (de abajo a arriba): I, F, S, A, D
 - Aunque igual otro orden sería más eficiente, pero eso no lo sabemos a priori

- Variable I :

- El factor $f_I(S, F)$ es $P(i|S, F)$ (no depende de I ya que su valor está determinado a i):

S	F		$f_{\{I\}}(S, F) = P(i S, F)$
s	f		0.8
no s	f		0.6
s	no f		0.7
no s	no f		0.3

- $FACTORES = \{f_I(S, F)\}$

Aplicando eliminación de variables

- Variable F :

- El factor $f_F(F)$ es $P(F)$:

F		$f_{\{F\}}(F)=P(F)$
f		0.4
no f		0.6

- $FACTORES = \{f_I(S, F), f_F(F)\}$

Aplicando eliminación de variables

- Variable S :

- El factor $f_S(S, A)$ es $P(S, \neg d, A)$ (no depende de D ya que su valor está determinado a $\neg d$):

S	A		$f_{\{S\}}(S, A) = P(S \text{no } d, A)$
s	a		0.25
s	no a		0.7
no s	a		0.75
no s	no a		0.3

- $FACTORES = \{f_I(S, F), f_F(F), f_S(S, A)\}$

Aplicando eliminación de variables

- Como S es una variable oculta, agrupamos por S
- Para ello, primero multiplicamos $f_I(S, F)$ y $f_S(S, A)$ obteniendo $g(S, A, F)$

S	A	F		$g(S, A, F) = P(S \text{no d}, A) \times P(i S, F)$
s	a	f		0.25 x 0.8
s	no a	f		0.7 x 0.8
s	a	no f		0.25 x 0.7
s	no a	no f		0.7 x 0.7
no s	a	f		0.75 x 0.6
no s	no a	f		0.3 x 0.6
no s	a	no f		0.75 x 0.3
no s	no a	no f		0.3 x 0.3

Aplicando eliminación de variables

- Y ahora, sumamos $g(S, A, F)$ por la variable S , obteniendo $h(A, F)$

A	F		$h(A, F) = \text{SUM}_{\{S\}} g(S, A, F)$
a	f		$0.25 \times 0.8 + 0.75 \times 0.6 = 0.65$
no a	f		$0.7 \times 0.8 + 0.3 \times 0.6 = 0.74$
a	no f		$0.25 \times 0.7 + 0.75 \times 0.3 = 0.4$
no a	no f		$0.7 \times 0.7 + 0.3 \times 0.3 = 0.58$

- Acabamos de eliminar la variable S
- $FACTORES = \{h(A, F), f_F(F)\}$ (nótese que $f_F(F)$ no se ha usado)

Aplicando eliminación de variables

- Variable A :

- El factor $f_A(A)$ es $P(A)$:

A		$f_{\{A\}}(A)=P(A)$
a		0.4
no a		0.6

- $FACTORES = \{f_A(A), h(A, F), f_F(F)\}$

Aplicando eliminación de variables

- Como A es una variable oculta, agrupamos por A
 - Para ello, primero multiplicamos $f_A(A)$ y $h(A, F)$ obteniendo $k(A, F)$

A	F		$k(F, A) = P(A) \times h(A, F)$
a	f		$0.4 \times 0.65 = 0.26$
no a	f		$0.6 \times 0.74 = 0.444$
a	no f		$0.4 \times 0.4 = 0.16$
no a	no f		$0.6 \times 0.58 = 0.348$

- Y ahora, sumamos $k(A, F)$ por la variable A , obteniendo $l(F)$ (y eliminando, por tanto, la variable S)

F		$l(F) = \text{SUM}_{\{A\}} k(A, F)$
f		$0.26 + 0.444 = 0.704$
no f		$0.16 + 0.348 = 0.508$

- $FACTORES = \{l(F), f_F(F)\}$

Aplicando eliminación de variables

- Variable D :

- Factor $f_D()$ (no depende de D , ya que su valor está fijado a $\neg d$, por tanto se trata de una tabla con una única entrada): 0,9

- $FACTORES = \{f_D(), l(F), f_F(F)\}$

- Ultimo paso: multiplicamos y normalizamos

- Obsérvese que sólo hasta este paso hacemos uso del factor correspondiente a F

- Multiplicación

F		$m(F)=f_d() \times l(F) \times f_F(F)$
f		$0.9 \times 0.704 \times 0.4 = 0.253$
no f		$0.9 \times 0.508 \times 0.6 = 0.274$

- Normalizando obtenemos finalmente: $P(F|i, \neg d) = \langle 0,48, 0,52 \rangle$

- Por tanto, la probabilidad de ser fumador, dado que se ha tenido un infarto y no se hace deporte, es del 48 %

Complejidad del algoritmo de eliminación de variables

- La complejidad del algoritmo (tanto en tiempo como en espacio) está dominada por el tamaño del mayor factor obtenido durante el proceso
- Y en eso influye el orden en el que se consideren las variables (*orden de eliminación*)
 - Podríamos usar un criterio heurístico para elegir el orden de eliminación
 - En general, es conveniente moverse “desde las hojas hacia arriba” (consistentemente con la topología de la red)
- Si la red está *simplemente conectada* (*poliárbol*) se puede probar que la complejidad del algoritmo (en tiempo y espacio) es *lineal* en el tamaño de la red (el número de entradas en sus tablas)
 - Una red está simplemente conectada si hay a lo sumo un camino (no dirigido) entre cada dos nodos

Complejidad de la inferencia exacta

- Pero en general, el algoritmo tiene complejidad exponencial (en tiempo y espacio) en el peor de los casos
- Cuando la inferencia exacta se hace inviable, es esencial usar métodos aproximados de inferencia
- Métodos estocásticos, basados en muestreos que simulan las distribuciones de probabilidad de la red

Aplicaciones de las redes bayesianas

- Aplicaciones en empresas
 - Microsoft: *Answer Wizard (Office)*, diagnóstico de problemas de impresora,...
 - Intel: Diagnóstico de fallos de procesadores
 - HP: Diagnóstico de problemas de impresora
 - Nasa: Ayuda a la decisión de misiones espaciales
- Otras aplicaciones: diagnóstico médico, *e-learning*,...

Bibliografía

- Russell, S. y Norvig, P. *Inteligencia artificial (Un enfoque moderno)*, segunda edición (Prentice–Hall Hispanoamericana, 2004)
 - Cap. 14: “Razonamiento Probabilístico”