

Métodos de Inteligencia Artificial

L. Enrique Sucar (INAOE)

esucar@inaoep.mx

ccc.inaoep.mx/esucar

Tecnologías de Información

UPAEP

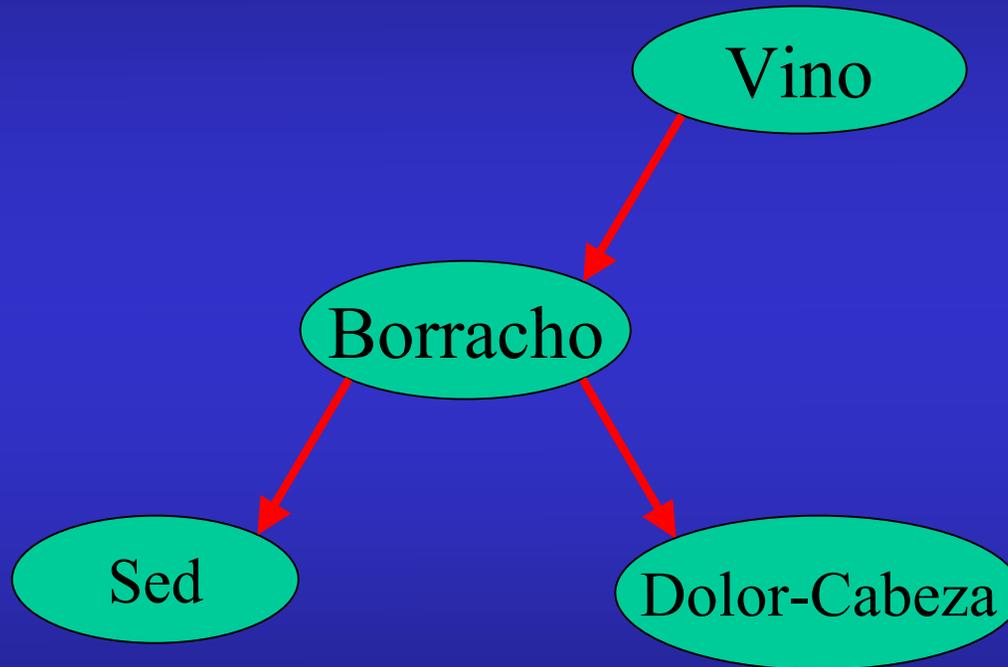
Redes Bayesianas: Parte I

- Introducción
- Representación
- Inferencia
 - Propagación en árboles

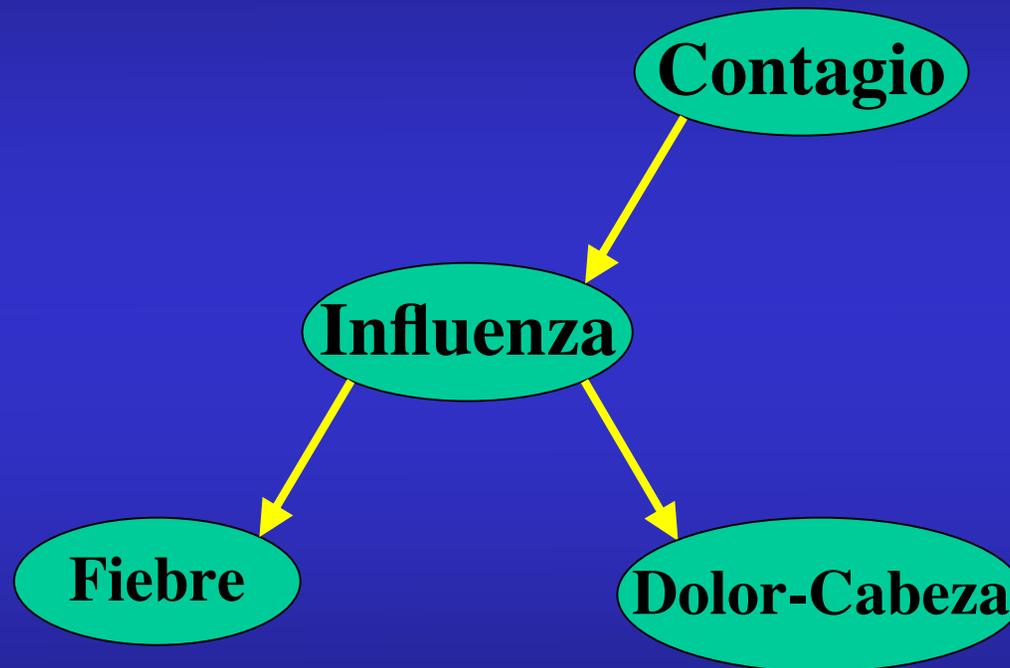
Representación

- Las redes bayesianas son una representación gráfica de dependencias para razonamiento probabilístico, en la cual los nodos y arcos representan:
 - Nodos: Variables proposicionales.
 - Arcos: Dependencia probabilística
- La variable a la que apunta el arco es dependiente (causa-efecto) de la que está en el origen de éste.

Ejemplo de una red bayesiana



Otro ejemplo ...



Podemos interpretar a una RB de dos formas:

1. Distribución de probabilidad:

Representa la distribución de la probabilidad conjunta de las variables representadas en la red.

Por ejemplo:

$$P(C, I, F, D) = P(C) P(I | C) P(F | I) P(D | I)$$

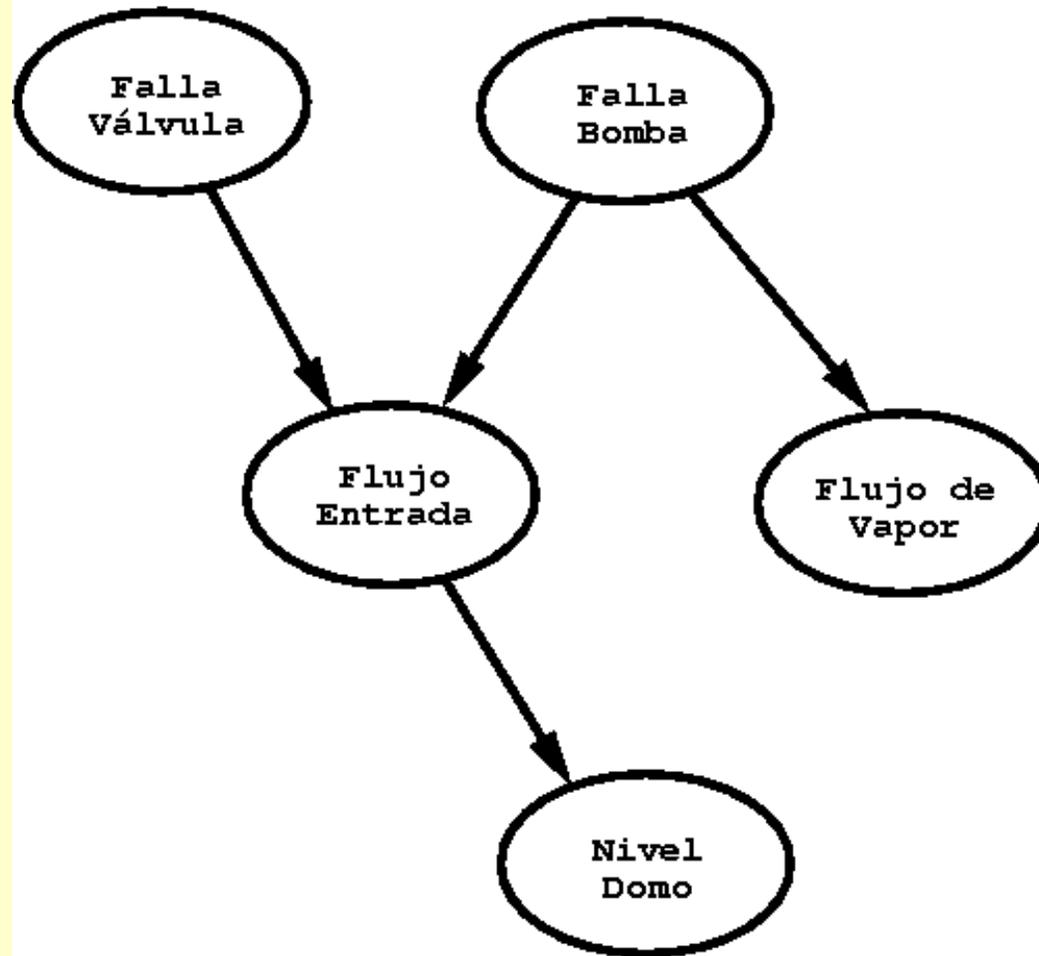
2. Base de reglas:

Cada arco representa un conjunto de reglas que asocian las variables involucradas,
Por ejemplo:

Si I entonces F

Dichas reglas están cuantificadas por las probabilidades respectivas.

Otro ejemplo



Estructura

- La topología o estructura de la red nos da información sobre las dependencias probabilísticas entre las variables.
- La red también representa las independencias condicionales de una variable (o conjunto de variables) dada otra variable(s).

Ejemplo

- Para el caso del domo:

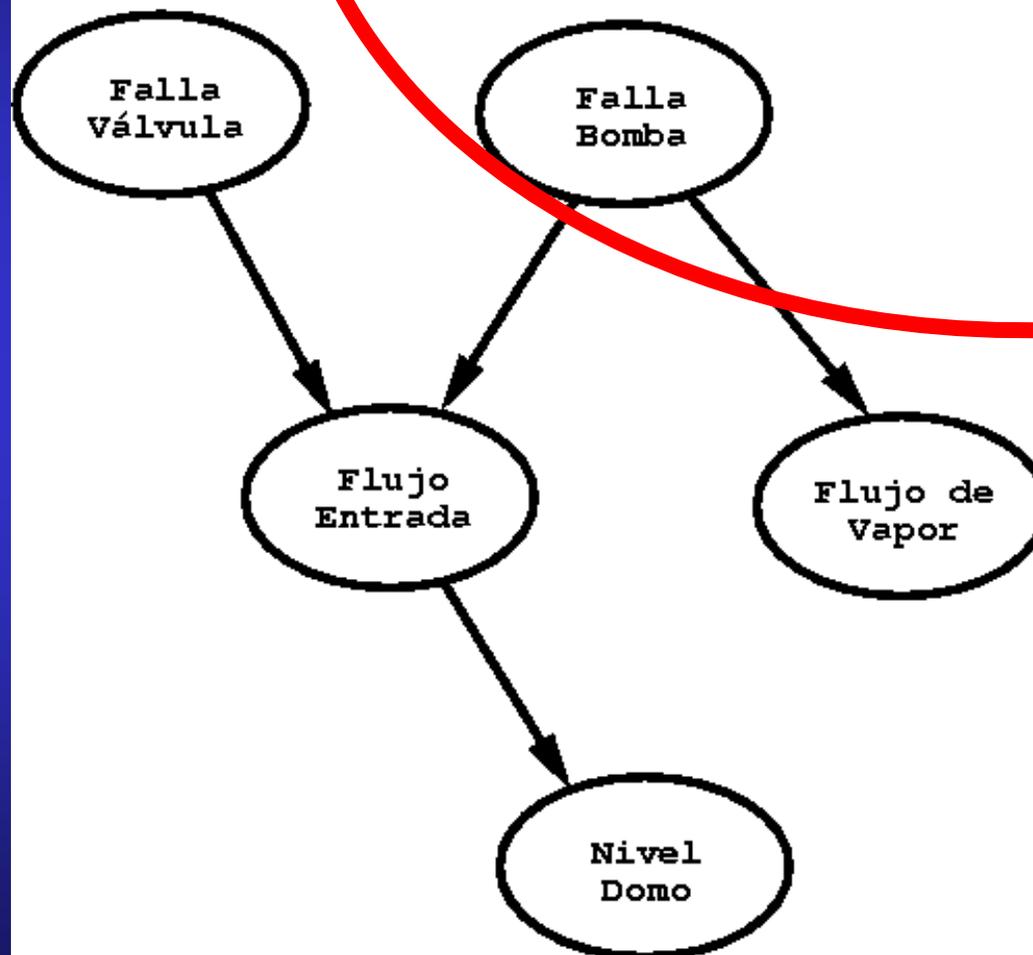
$\{Fva\}$ es cond. indep. de $\{Fv, Fe, Nd\}$ dado $\{Fb\}$

- Esto es:

$$P(Fva \mid Fv, Fe, Nd, Fb) = P(Fva \mid Fb)$$

- Esto se representa gráficamente por el nodo Fb separando al nodo Fva del resto de las variables.

Ejemplo de Red Bayesiana



Independencias condicionales

- En una RB todas las relaciones de independencia condicional representadas en el grafo corresponden a relaciones de independencia en la distribución de probabilidad.
- Dichas independencias simplifican la representación del conocimiento (menos parámetros) y el razonamiento (propagación de las probabilidades).

Representación Gráfica

- Una red bayesiana representa en forma gráfica las dependencias e independencias entre variables aleatorias, en particular las independencias condicionales
- Independencia en la distribución
 - $P(X | Y, Z) = P(X | Z)$
- Independencia en el grafo
 - X “separada” de Y por Z

Representación Gráfica

Notación:

- Independencia en la distribución
 - $I(X,Z,Y)$
- Independencia en el grafo
 - $\langle X | Z | Y \rangle$



Separación “D”

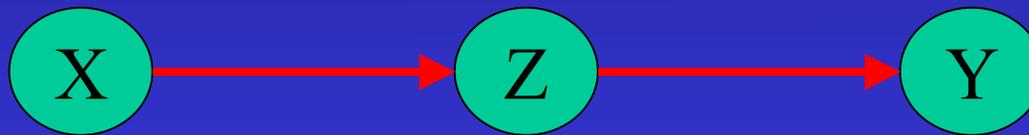
- El conjunto de variables A es independiente del conjunto B dado el conjunto C , si no existe trayectoria entre A y B en que
 1. Todos los nodos convergentes están o tienen descendientes en C
 2. Todos los demás nodos están fuera de C

Separación “D”

- Tres casos básicos
 - Arcos divergentes
 - Arcos en secuencia
 - Arcos convergentes

Separación “D” – casos básicos

- caso 1: Secuencia:



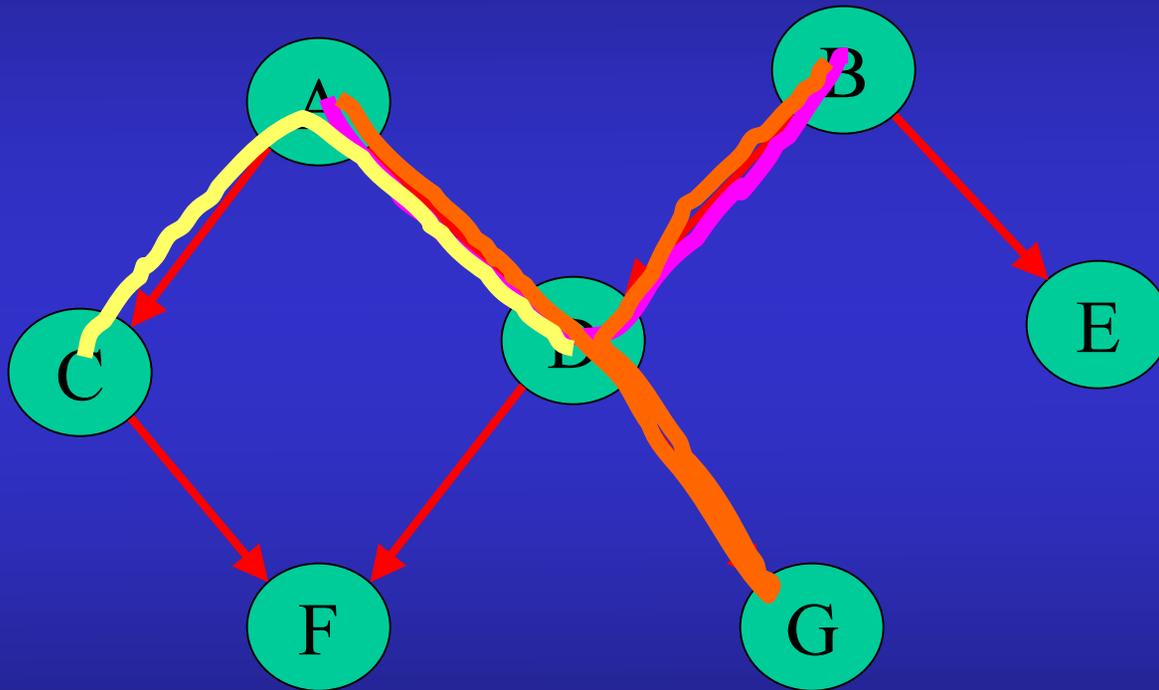
- caso 2: Divergentes:



- caso 3: Convergentes:



Ejemplos Separación-D



¿I(A,CD,F)?

¿I(A,CD,B)?

¿I(BD,A,C)?

¿I(A,G,B)?

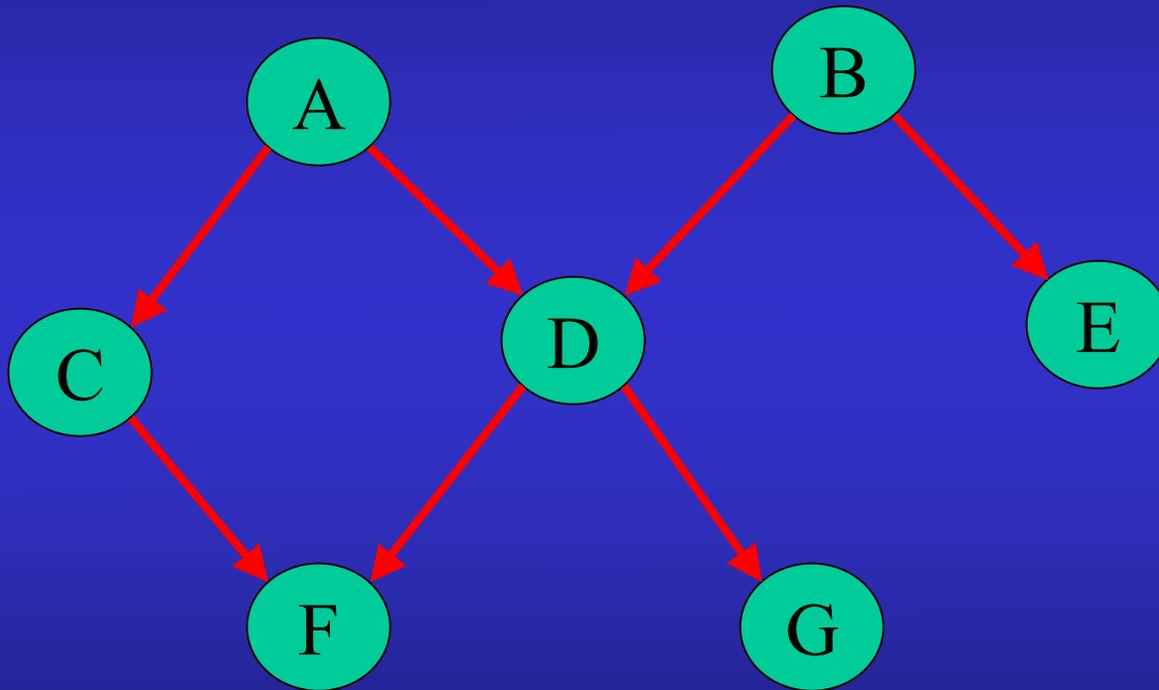
¿I(A,D,G)?

¿I(C,BEG,D)?

Especificación Estructural

- En una RB, cualquier nodo X es independiente de todos los nodos que no son sus descendientes dados sus nodos padres $\text{Pa}(X)$ – “contorno de X ”
- La estructura de una RB se especifica indicando el contorno (padres) de cada variable

Especificación Estructural



$$Pa(A) = 0$$

$$Pa(B) = 0$$

$$Pa(C) = A$$

$$Pa(D) = A, B$$

$$Pa(E) = B$$

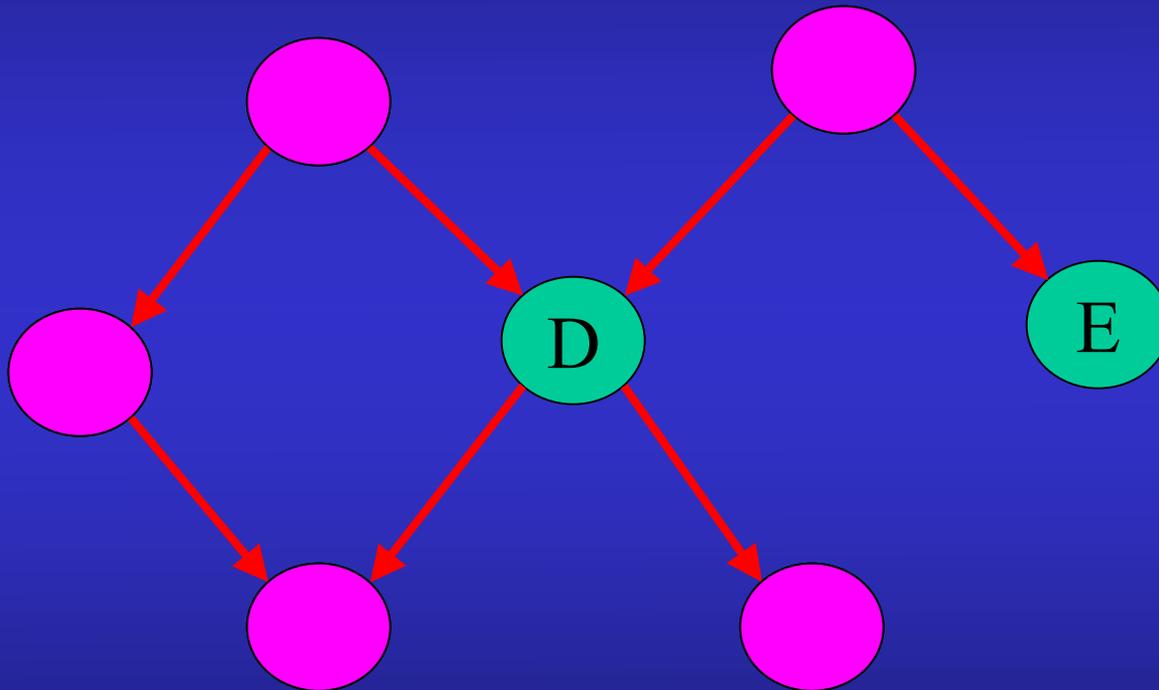
$$Pa(F) = C, D$$

$$Pa(G) = D$$

Cobija de Markov

- La “cobija de Markov” de un nodo es el conjunto de nodos que lo hacen independiente del resto de la red
- Para una RB la cobija de Markov está formada por:
 - Nodos padre
 - Nodos hijo
 - Otros padres de los hijos

Cobija de Markov

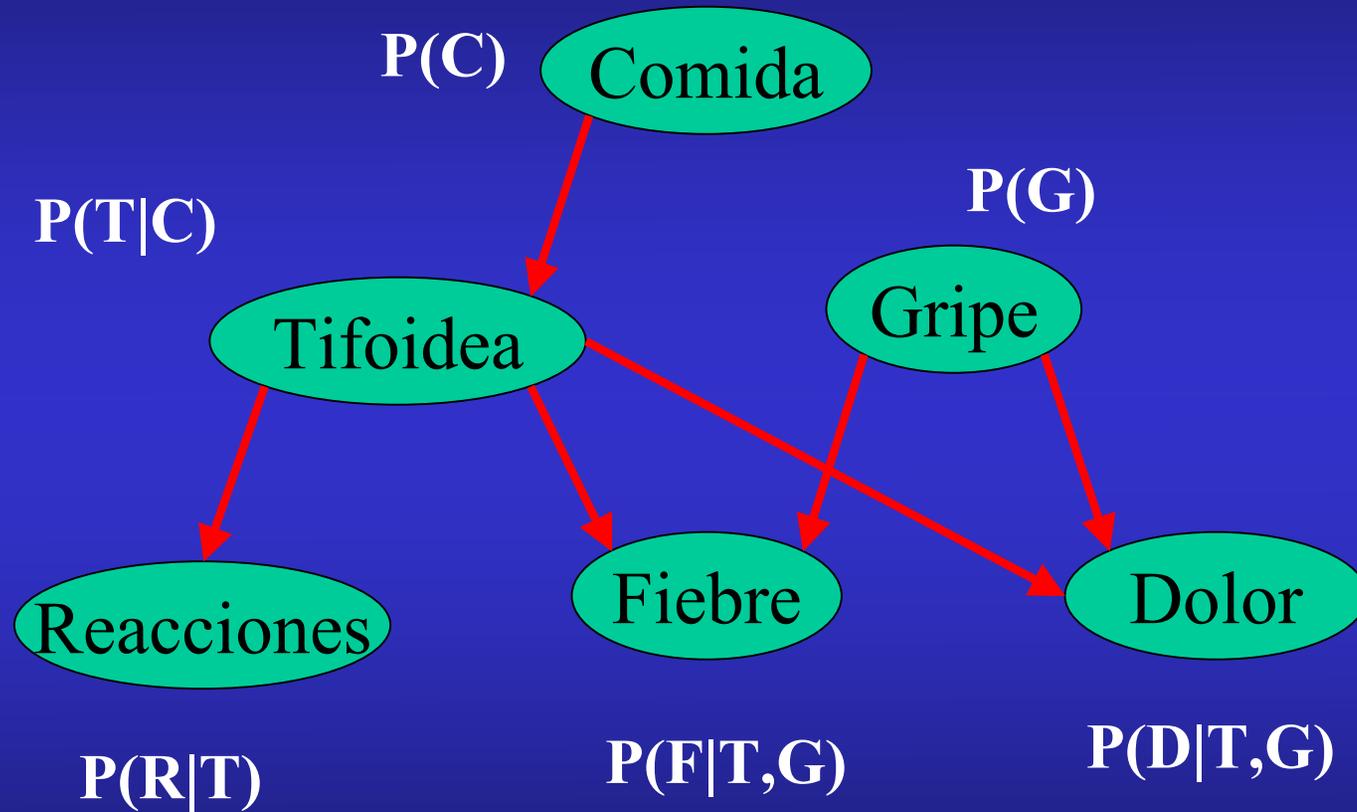


CM (D) ?

Parámetros

- Complementan la definición de una red bayesiana las probabilidades condicionales de cada variable dados sus padres.
 - **Nodos raíz:** vector de probabilidades marginales
 - **Otros nodos:** matriz de probabilidades condicionales dados sus padres

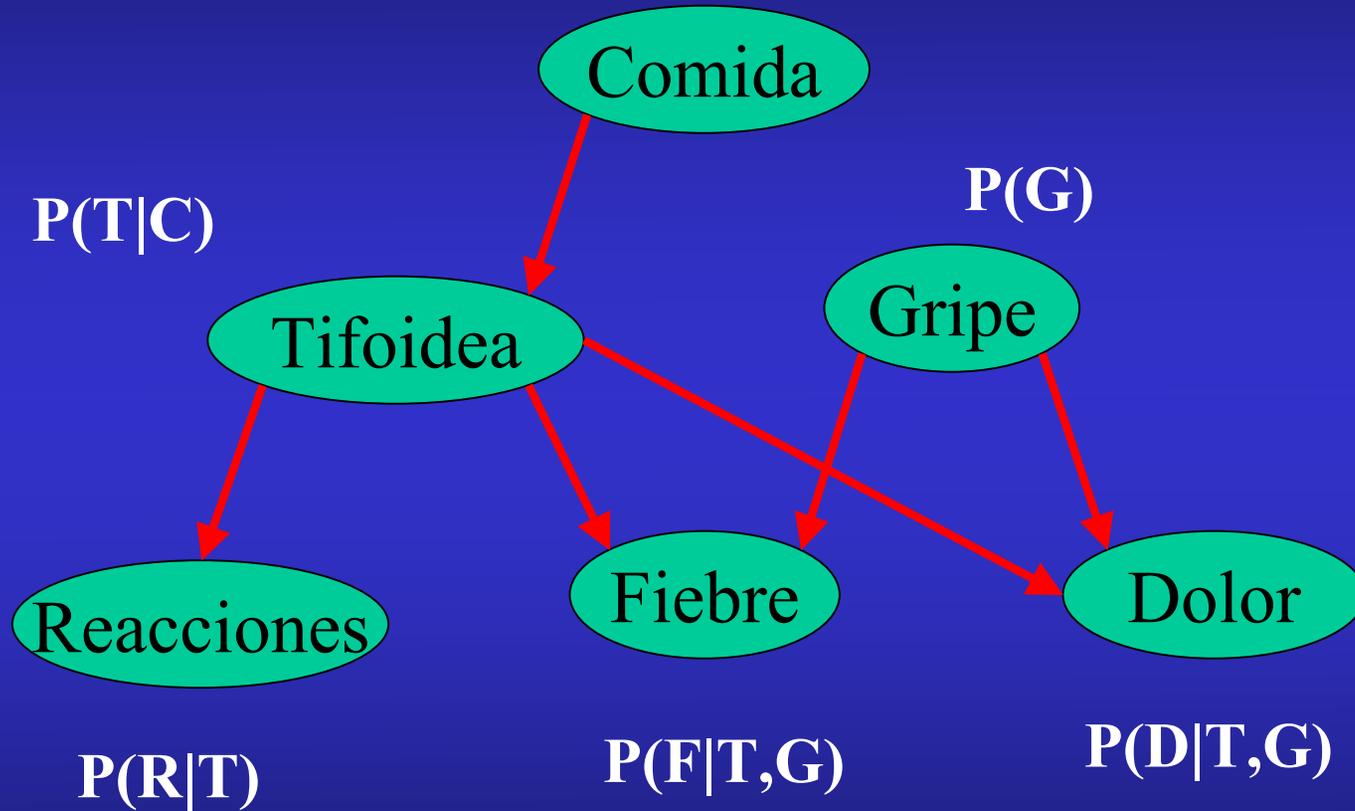
Ejemplo



Ejemplo

$P(C)$

Ins	Sal
0.2	0.8

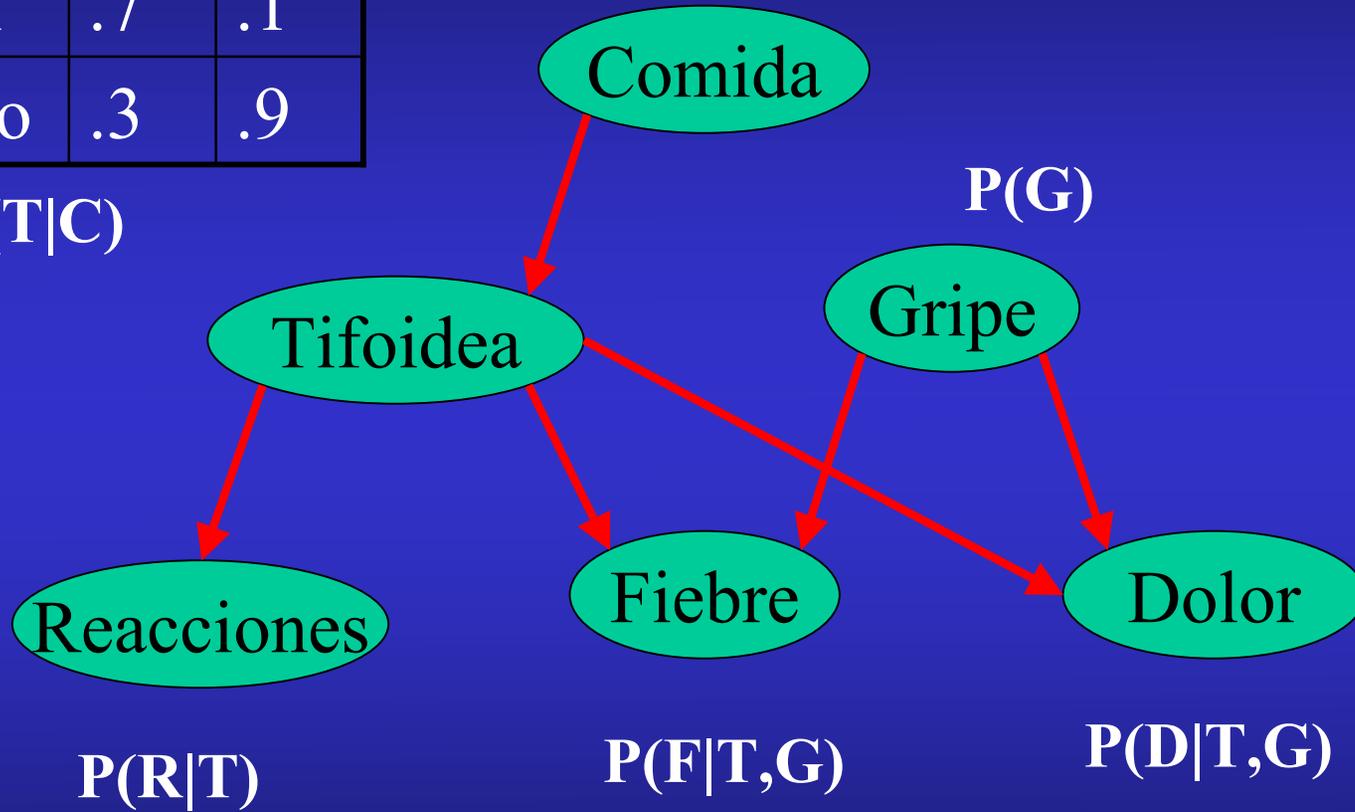


	Ins	Sal
Si	.7	.1
No	.3	.9

$P(T|C)$

$P(C)$

Ins	Sal
0.2	0.8



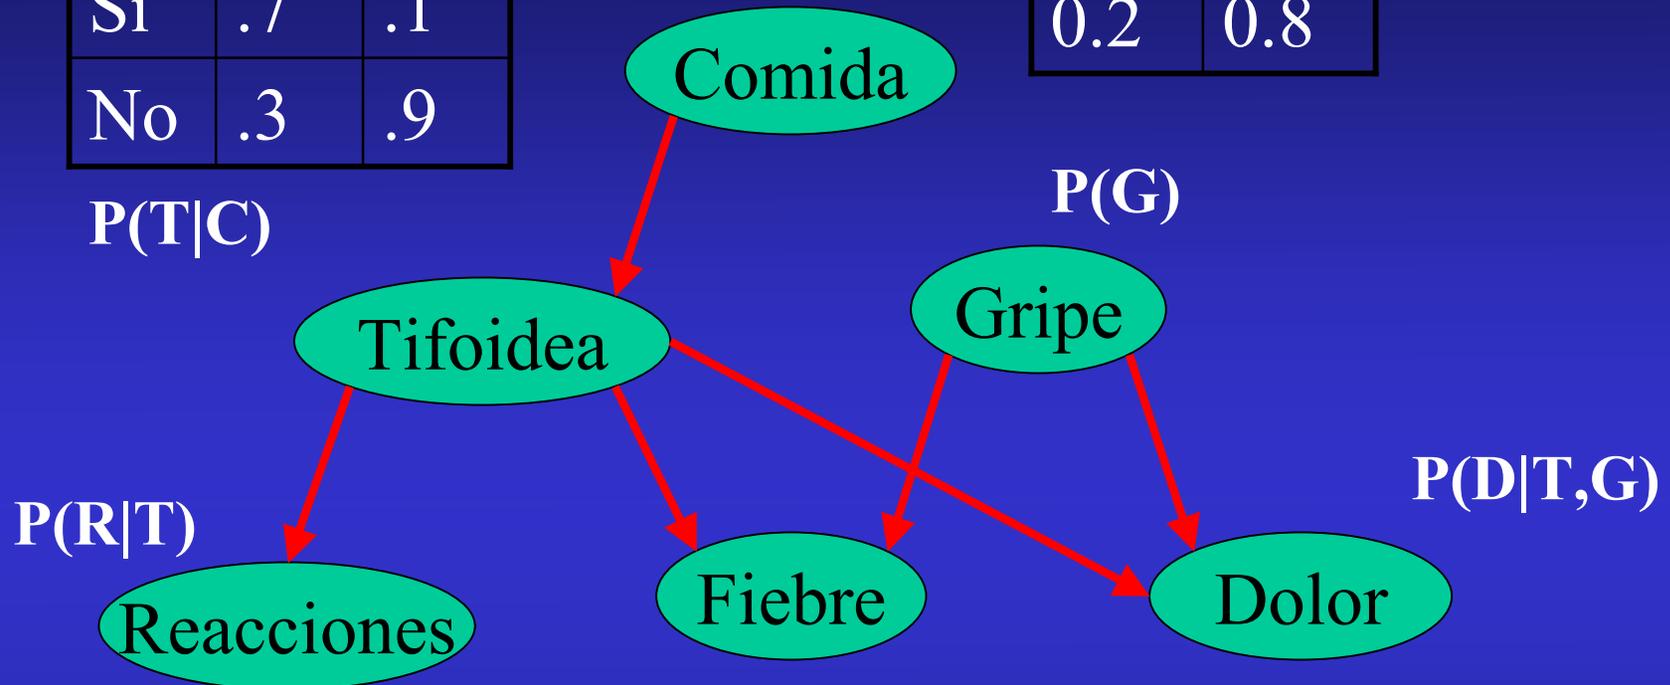
	Ins	Sal
Si	.7	.1
No	.3	.9

$P(T|C)$

Ins	Sal
0.2	0.8

$P(C)$

$P(G)$



$P(R|T)$

$P(D|T,G)$

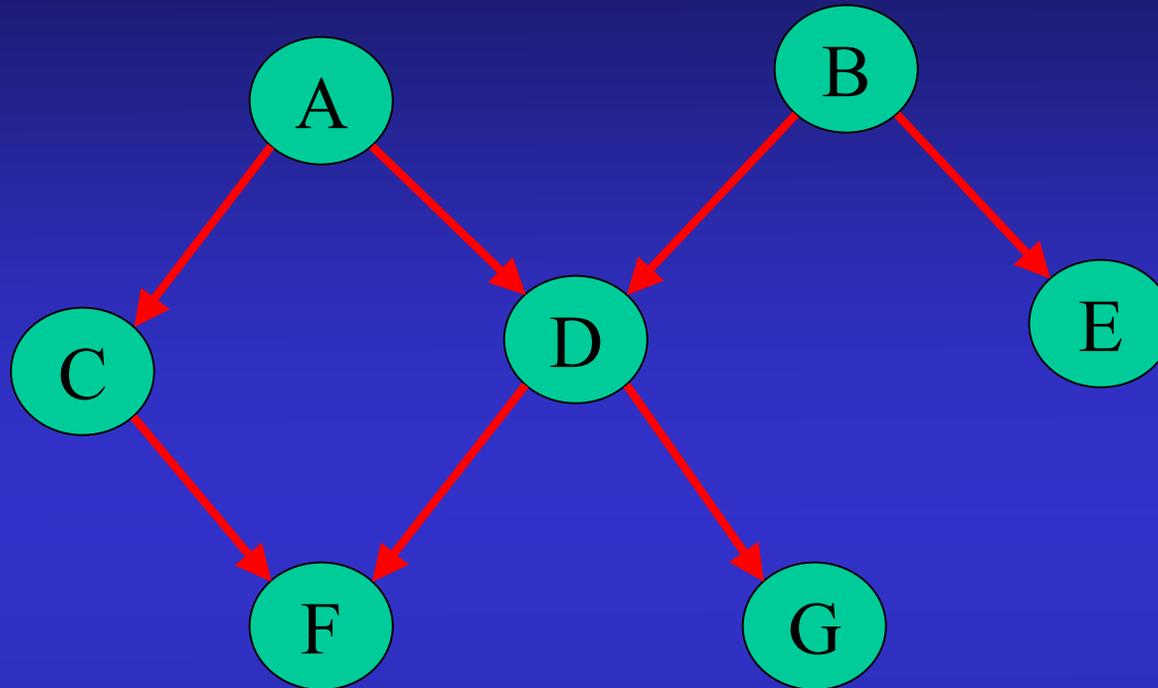
$P(F|T,G)$

	Si, Si	Si, No	No, Si	No, No
F	0.8	0.6	0.5	0.1
$\sim F$	0.2	0.4	0.5	0.9

Especificación Paramétrica

- Dado que los contornos (padres) de cada nodo especifican la estructura, mediante las probabilidades condicionales de dichos nodos podemos especificar también las probabilidades requeridas
- Aplicando la regla de la cadena y las independencias condicionales, se puede verificar que con dichas probabilidades se puede calcular la probabilidad conjunta

Especificación Paramétrica



$P(A,B,C,D,E,F,G)$

$= P(G|F,E,D,C,B,A) P(F|E,D,C,B,A) P(E|D,C,B,A)$

$P(D|C,B,A) P(C|B,A) P(B|A) P(A)$

$= P(G|D) P(F|D,C) P(E|B) P(D|B,A) P(C|A) P(B) P(A)$

Especificación Paramétrica

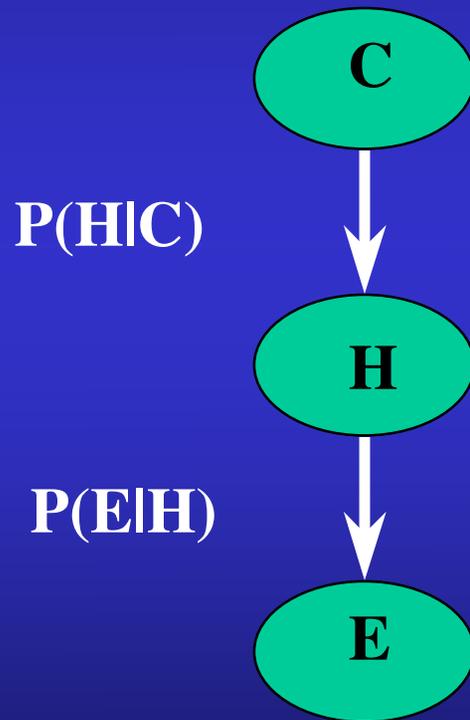
- En general, la probabilidad conjunta se especifica por el producto de las probabilidades de cada variable dados sus padres:

$$P(X_1, X_2, \dots, X_n) = \prod P(X_i \mid \text{Pa}(X_i))$$

Inferencia probabilística

- En RB, la inferencia probabilística consiste en:
“dadas ciertas variables conocidas (evidencia), calcular la probabilidad posterior de las demás variables (desconocidas)”
- Es decir, calcular: $P(X_i | E)$, donde:
 - E es un subconjunto de variables de la RB (posiblemente vacío)
 - X_i es cualquier variable en la RB, no en E

Inferencia bayesiana



Causal:

$$C \rightarrow H$$

Evidencial:

$$E \rightarrow H$$

Mixta:

$$C, E \rightarrow H$$

Tipos de Técnicas

- Calcular probabilidades posteriores:
 - Una variable, cualquier estructura: algoritmo de eliminación (*variable elimination*)
 - Todas las variable, estructuras sencillamente conectadas (árboles, poliárboles): propagación
 - Todas las variables, cualquier estructura:
 - Agrupamiento (*junction tree*)
 - Simulación estocástica
 - Condicionamiento

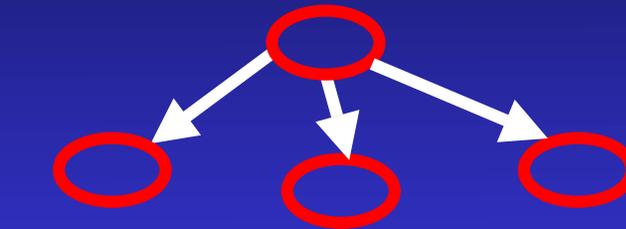
Tipos de Técnicas

- Obtener variable(s) de mayor probabilidad dada cierta evidencia – abducción:
 - Abducción total
 - Abducción parcial

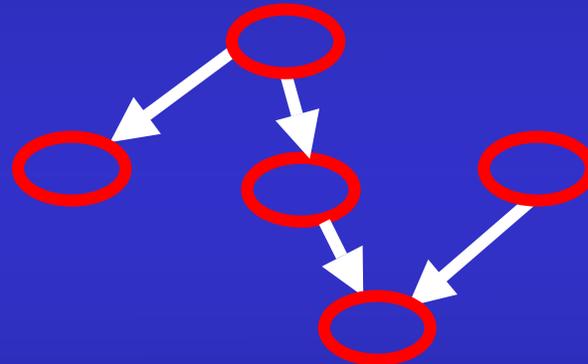
Tipos de estructuras

- Sencillamente conectadas

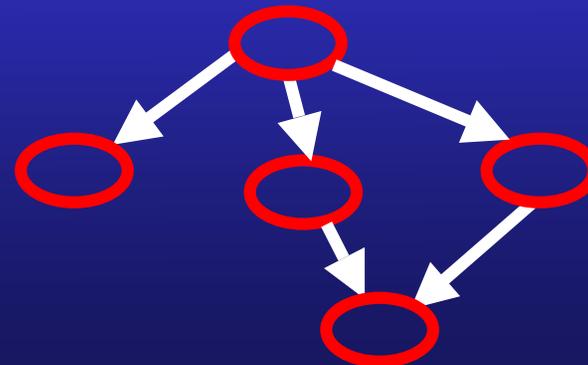
- Árboles



- Poliárboles



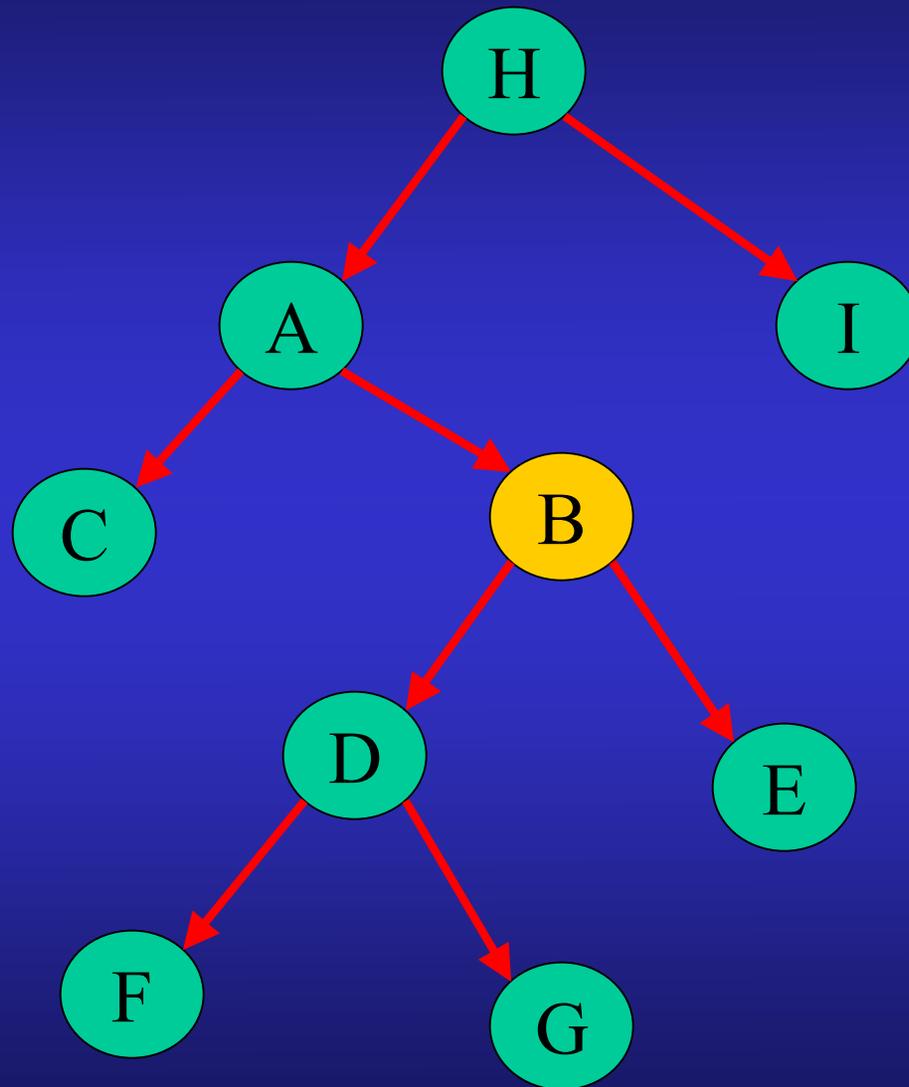
- Multiconectadas



Propagación en Árboles

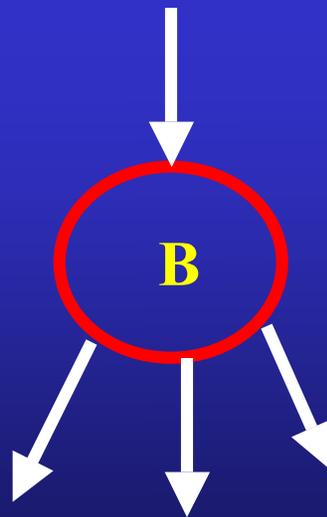
Cada nodo corresponde a una variable discreta, B (B_1, B_2, \dots, B_m) con su respectiva matriz de probabilidad condicional, $P(B|A)=P(B_j|A_i)$

Propagación en Árboles

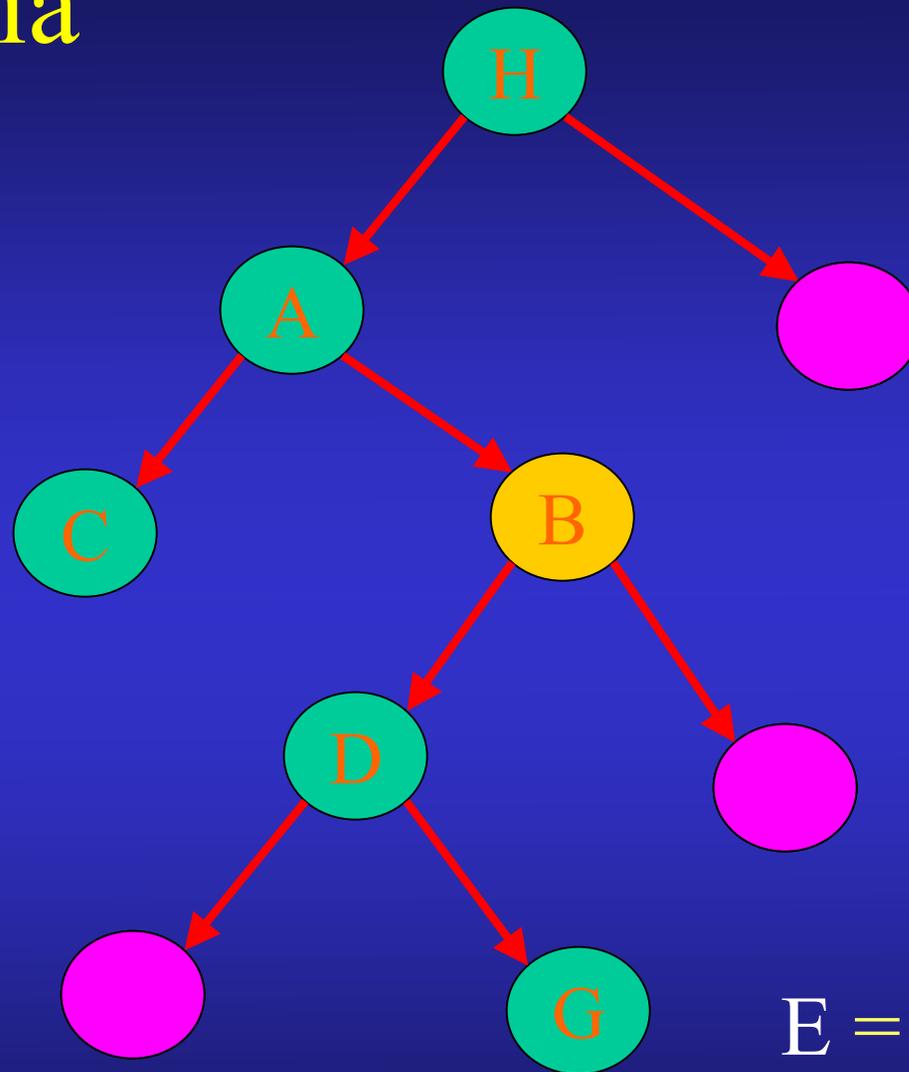


Dada cierta evidencia E -representada por la instanciación de ciertas variables- la probabilidad posterior de cualquier variable B , por el teorema de Bayes:

$$P(B_i | E) = P(B_i) P(E | B_i) / P(E)$$



Evidencia



$E = \{I, F, E\}$

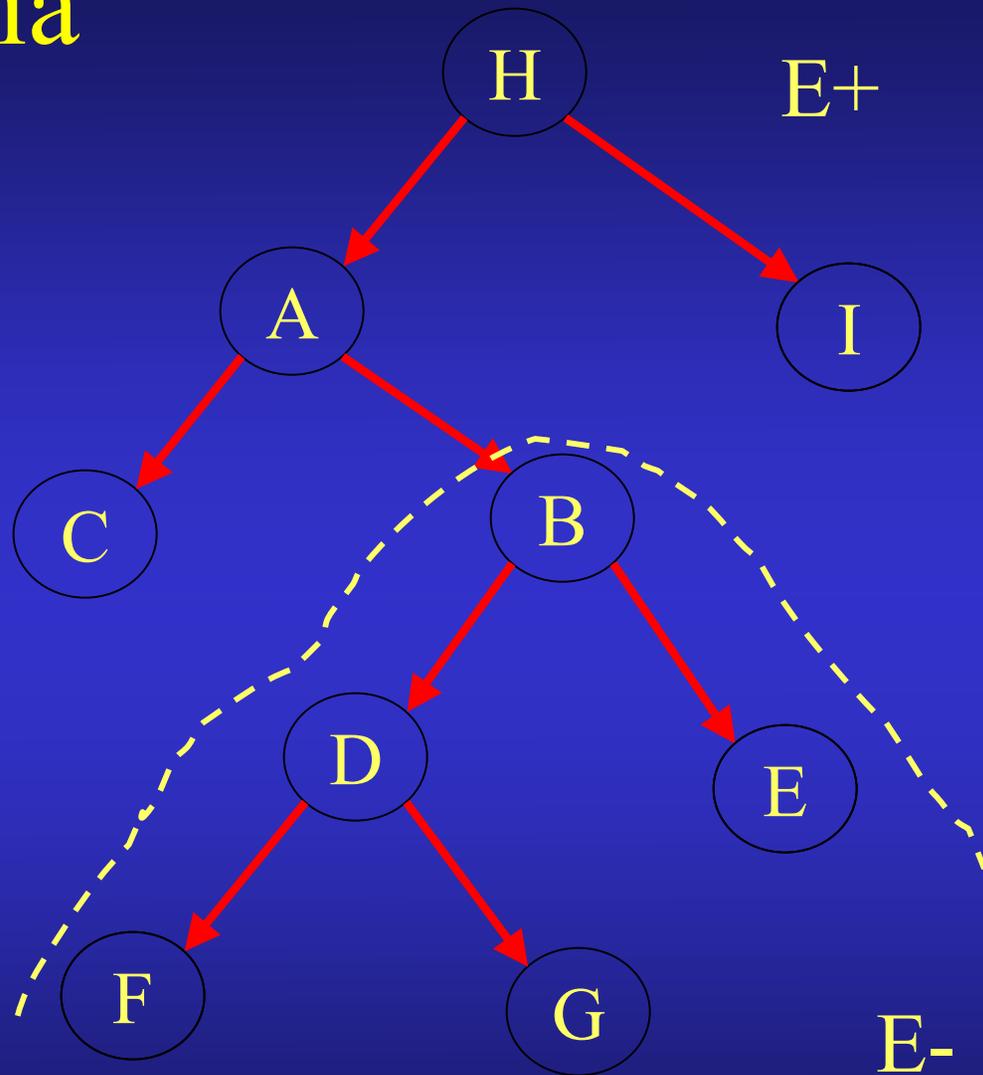
Evidencia

Ya que la estructura de la red es un árbol, el Nodo B la separa en dos subárboles, por lo que podemos dividir la evidencia en dos grupos:

E^- : Datos en el árbol que cuya raíz es B

E^+ : Datos en el resto del árbol

Evidencia



Entonces:

$$P(B_i | E) = P(B_i) P(E^-, E^+ | B_i) / P(E)$$

Pero dado que ambos son independientes y aplicando nuevamente Bayes:

$$P(B_i | E) = \alpha P(B_i | E^+) P(E^- | B_i)$$

Donde α es una constante de normalización

Definiciones:

Si definimos los siguientes términos:

$$\lambda (B_i) = P (E^- | B_i)$$

$$\pi (B_i) = P (B_i | E^+)$$

Entonces:

$$P(B_i | E) = \alpha \pi (B_i) \lambda (B_i)$$

Desarrollo

- En base a la ecuación anterior, se puede integrar un algoritmo distribuido para obtener la probabilidad de un nodo dada cierta evidencia
- Para ello se descompone el cálculo de cada parte:
 - Evidencia de los hijos (λ)
 - Evidencia de los demás nodos (π)

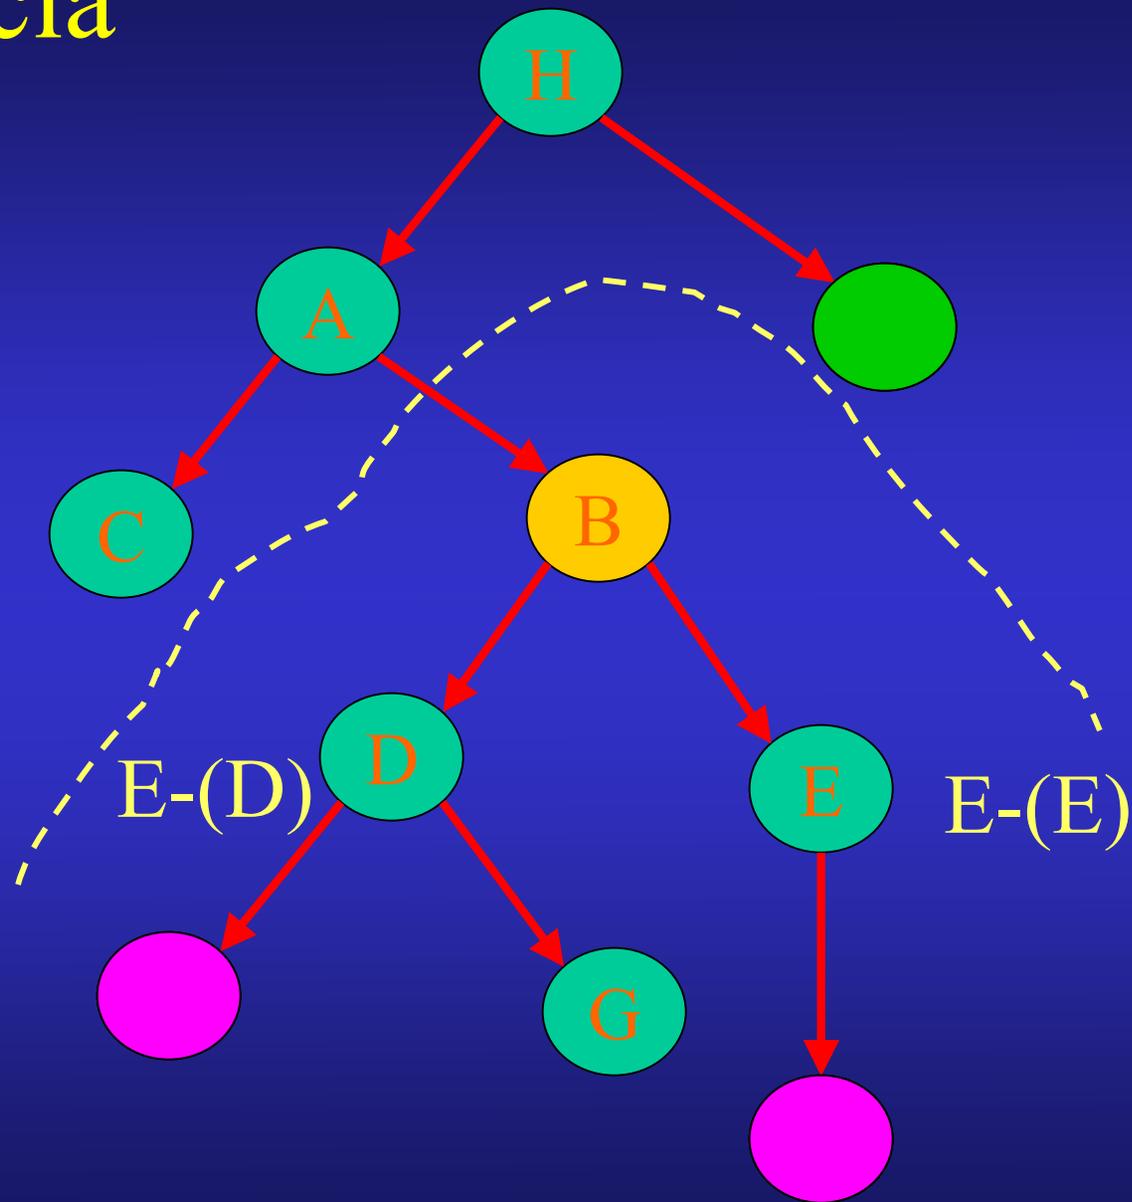
Evidencia de los hijos (I)

- Dado que los hijos son condicionalmente independientes dado el padre:

$$\lambda (B_i) = P (E^- | B_i) = \prod_k P (E_k^- | B_i)$$

- Donde E_k^- corresponde a la evidencia del subárbol del hijo k

Evidencia hijos



Evidencia de los hijos (λ)

- Condicionando respecto a los posibles valores de los hijos de B:

$$\lambda (B_i) = \prod_k \left[\sum_j P (E_k^- | B_i, S_j^k) P(S_j^k | B_i) \right]$$

- Donde S^k es el hijo k de B, y la sumatoria es sobre los valores de dicho nodo (teorema de probabilidad total)

Evidencia de los hijos (λ)

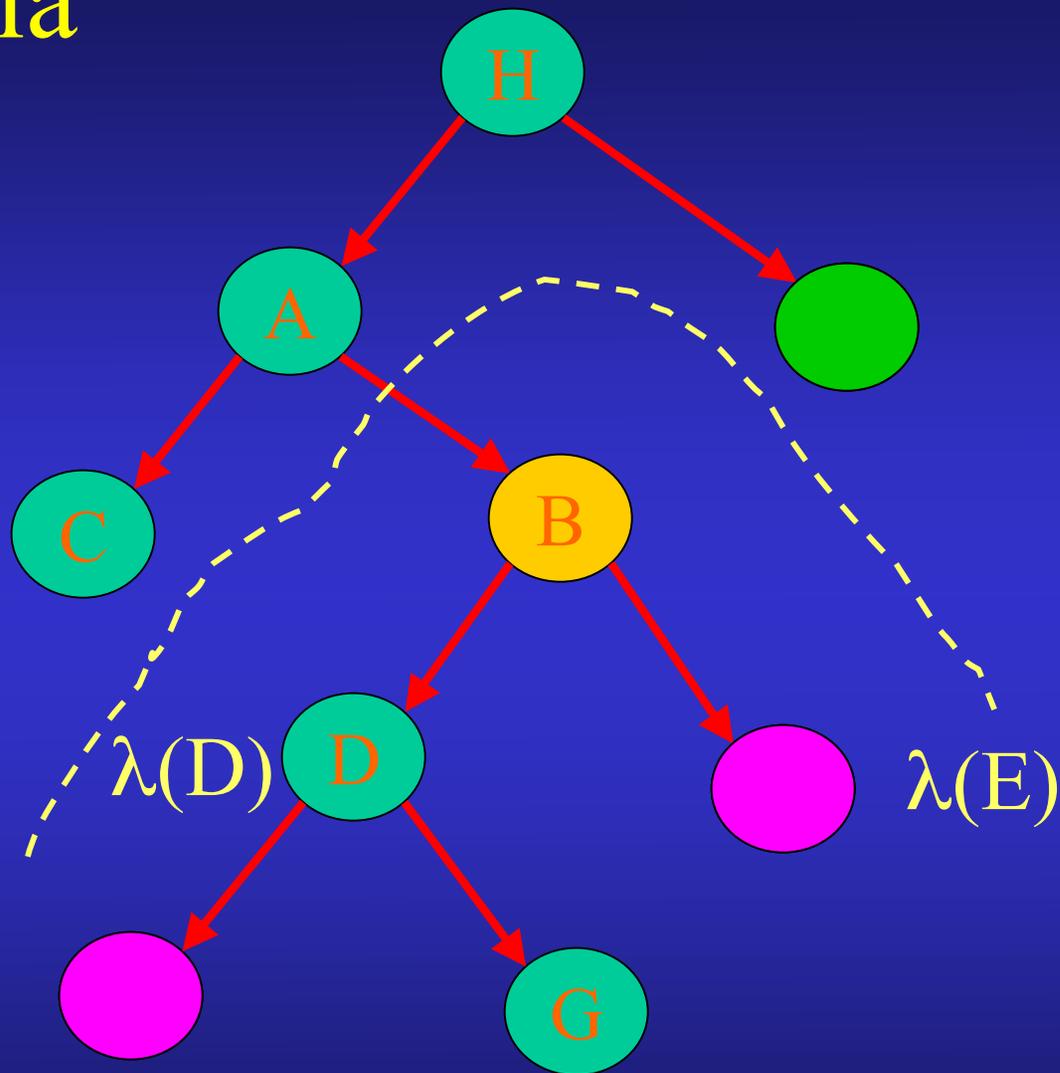
- Dado que B es condicionalmente independiente de la evidencia dados sus hijos:

$$\lambda (B_i) = \prod_k [\sum_j P (E_k^i | S_j^k) P(S_j^k | B_i)]$$

- Substituyendo la definición de λ :

$$\lambda (B_i) = \prod_k [\sum_j P(S_j^k | B_i) \lambda (S_j^k)]$$

Evidencia hijos



Evidencia de los hijos (I)

- Recordando que λ es un vector (un valor por cada posible valor de B), lo podemos ver en forma matricial:

$$\boxed{\lambda} = \boxed{\lambda} \boxed{P(S | B)}$$

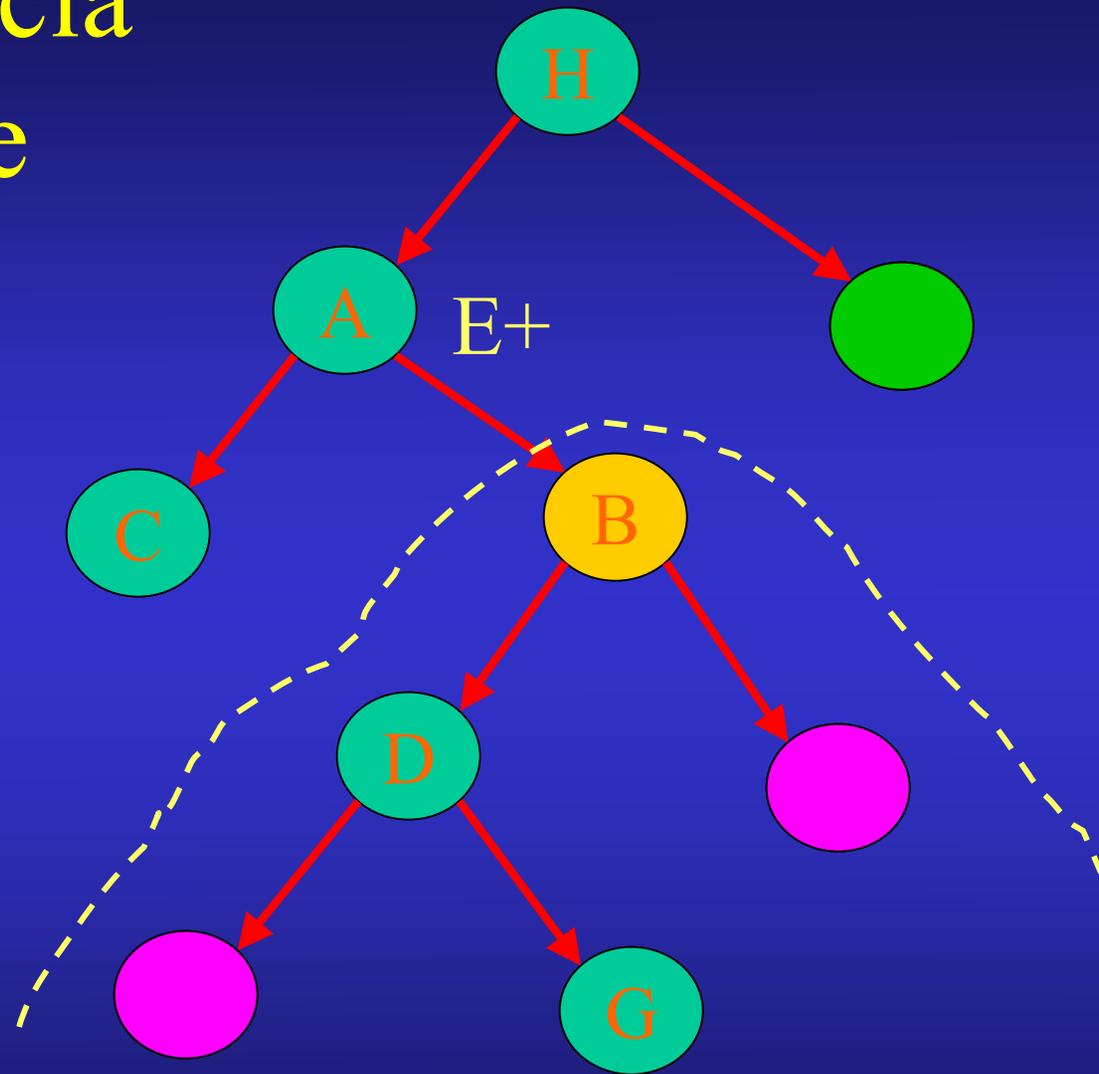
Evidencia de los demás nodos (π)

- Condicionando sobre los diferentes valores del nodo padre (A):

$$\pi (B_i) = P (B_i | E^+) = \sum_j P (B_i | E^+, A_j) P(A_j | E^+)$$

- Donde A_j corresponde a los diferentes valores del nodo padre de B

Evidencia padre



Evidencia de los demás nodos (p)

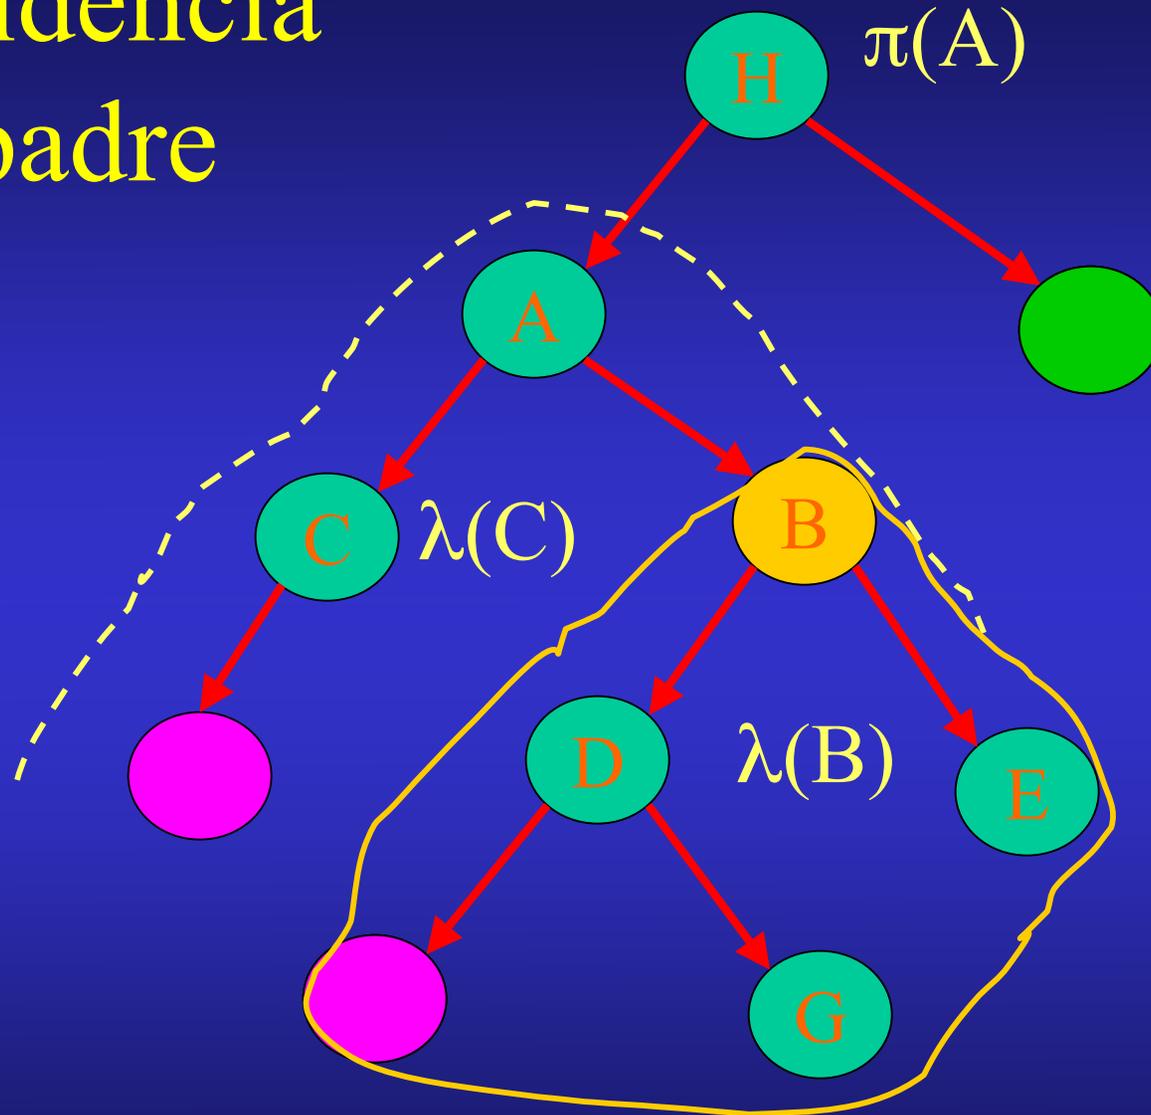
- Dado que B es independiente de la evidencia “arriba” de A, dado A:

$$\prod (B_i) = \sum_j P(B_i | A_j) P(A_j | E^+)$$

- La $P(A_j | E^+)$ corresponde a la P posterior de A dada toda la evidencia excepto B y sus hijos, por lo que se puede escribir como:

$$P(A_j | E^+) = \alpha \pi(A_i) \prod_{k^1 B} \lambda_k(A_i)$$

Evidencia padre



Evidencia de los demás nodos (π)

- Substituyendo $P(A_j | E^+)$ en la ecuación de π :

$$\pi(B_i) = \sum_j P(B_i | A_j) \left[\alpha \pi(A_i) \prod_{k \in \text{children}(i)} \lambda_k(A_i) \right]$$

- De forma que se obtiene combinando la π de del nodo padre con la λ de los demás hijos

Evidencia de los demás nodos (\mathbf{p})

- Dado que también π es un vector, lo podemos ver en forma matricial (donde P_A es el producto de la evidencia de padre y otros hijos):

$$\begin{array}{|c|} \hline \pi \\ \hline \end{array} = \begin{array}{|c|} \hline P(B | A) \\ \hline \end{array} \begin{array}{|c|} \hline P_A \\ \hline \end{array}$$

Algoritmo

- Mediante estas ecuaciones se integra un algoritmo de propagación de probabilidades en árboles.
- Cada nodo guarda los valores de los vectores π y λ , así como su matriz de probabilidad condicional (CPT), P .
- La propagación se hace por un mecanismo de paso de mensajes, en donde cada nodo envía los mensajes correspondientes a su padre e hijos

**Mensaje al padre (hacia arriba) –
nodo B a su padre A:**

$$\lambda_B(A_i) = \sum_j P(B_j|A_i) \lambda(B_j)$$

**Mensaje a los hijos (hacia abajo) -
nodo B a su hijo S_k :**

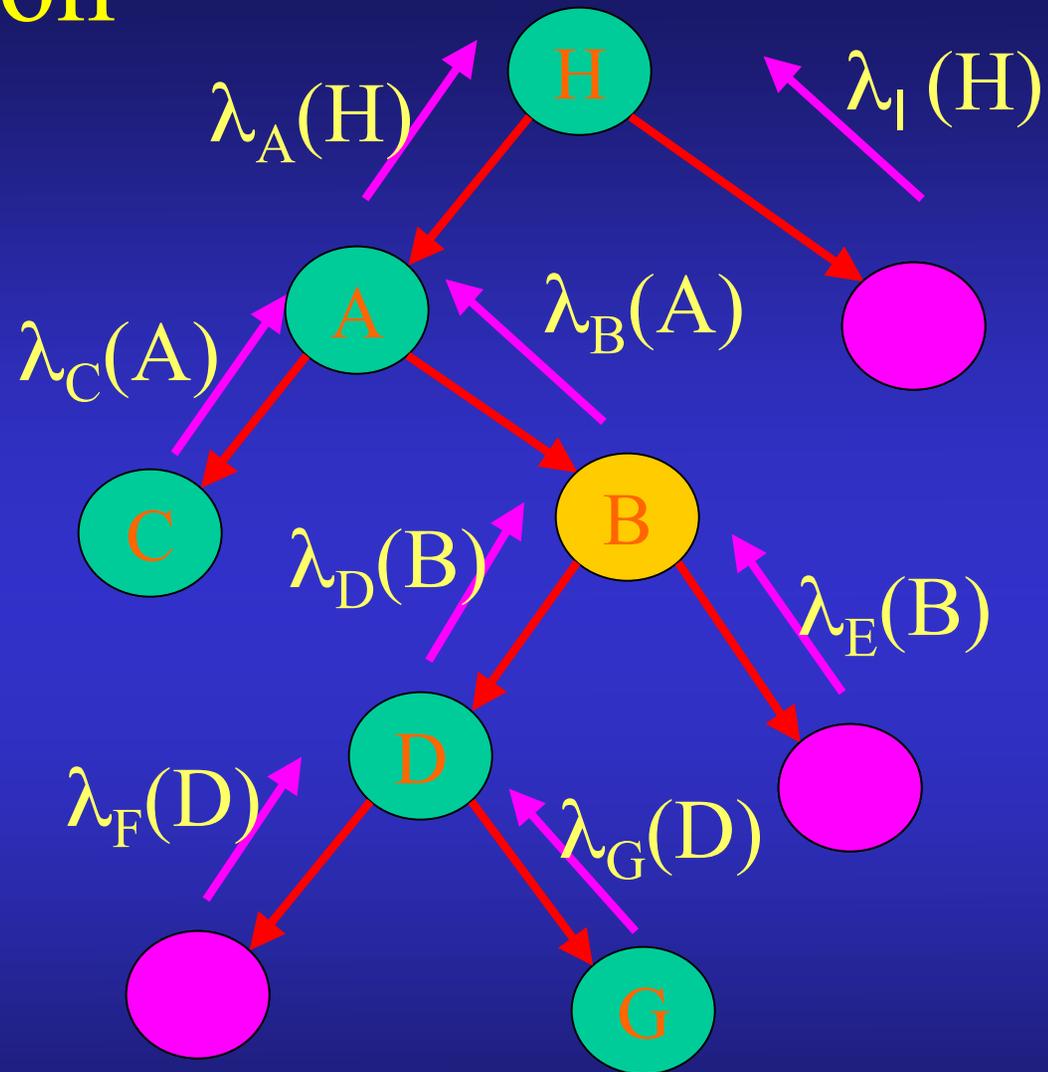
$$\pi_k(B_i) = \alpha \pi(B_j) \prod_{I \neq k} \lambda_I(B_j)$$

Algoritmo

- Al instanciarse ciertos nodos, éstos envían mensajes a sus padres e hijos, y se propagan hasta a llegar a la raíz u hojas, o hasta encontrar un nodo instanciado.
- Así que la propagación se hace en un solo paso, en un tiempo proporcional al diámetro de la red.

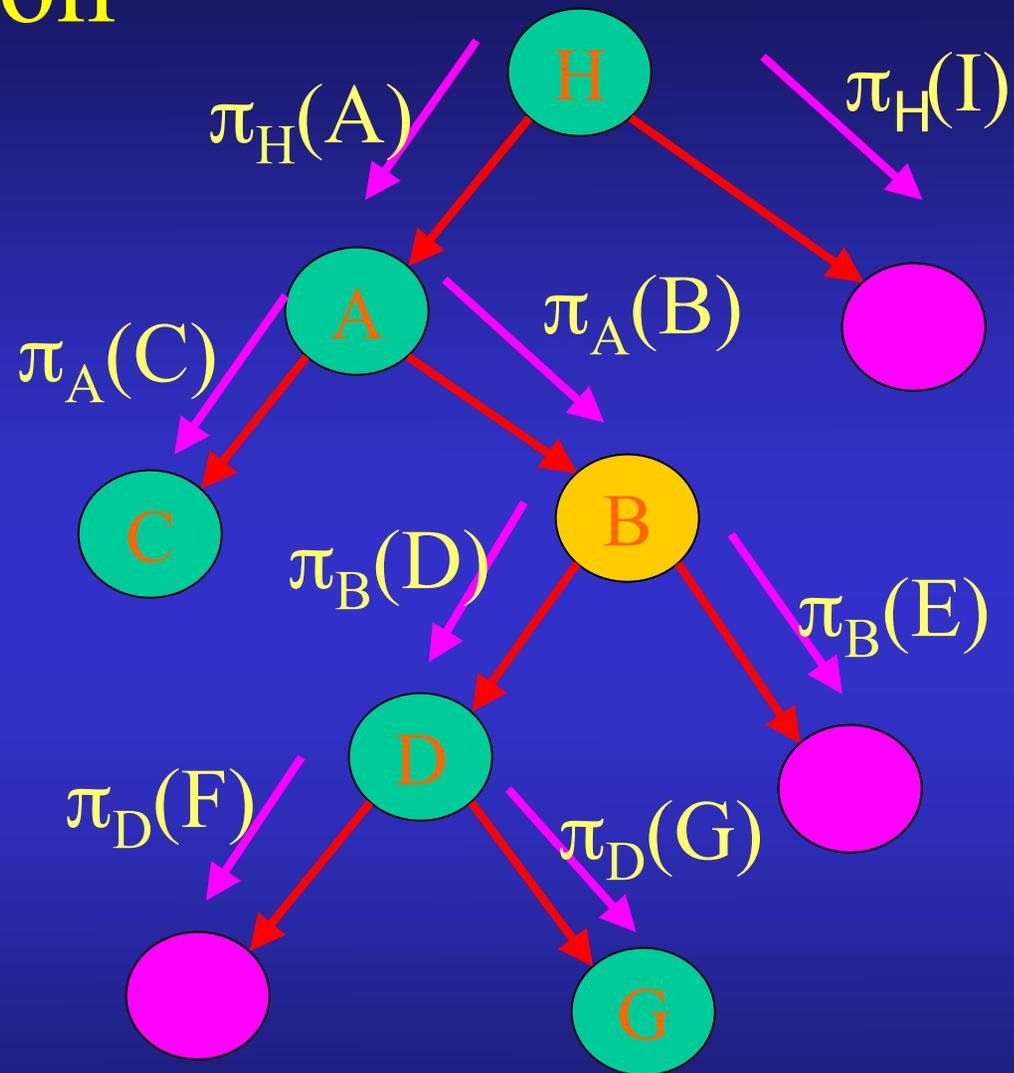
Propagación

$\hat{\lambda}$



Propagación

π



Condiciones Iniciales

- Nodos hoja no conocidos:

$$\lambda (B_i) = [1, 1, \dots]$$

- Nodos asignados (conocidos):

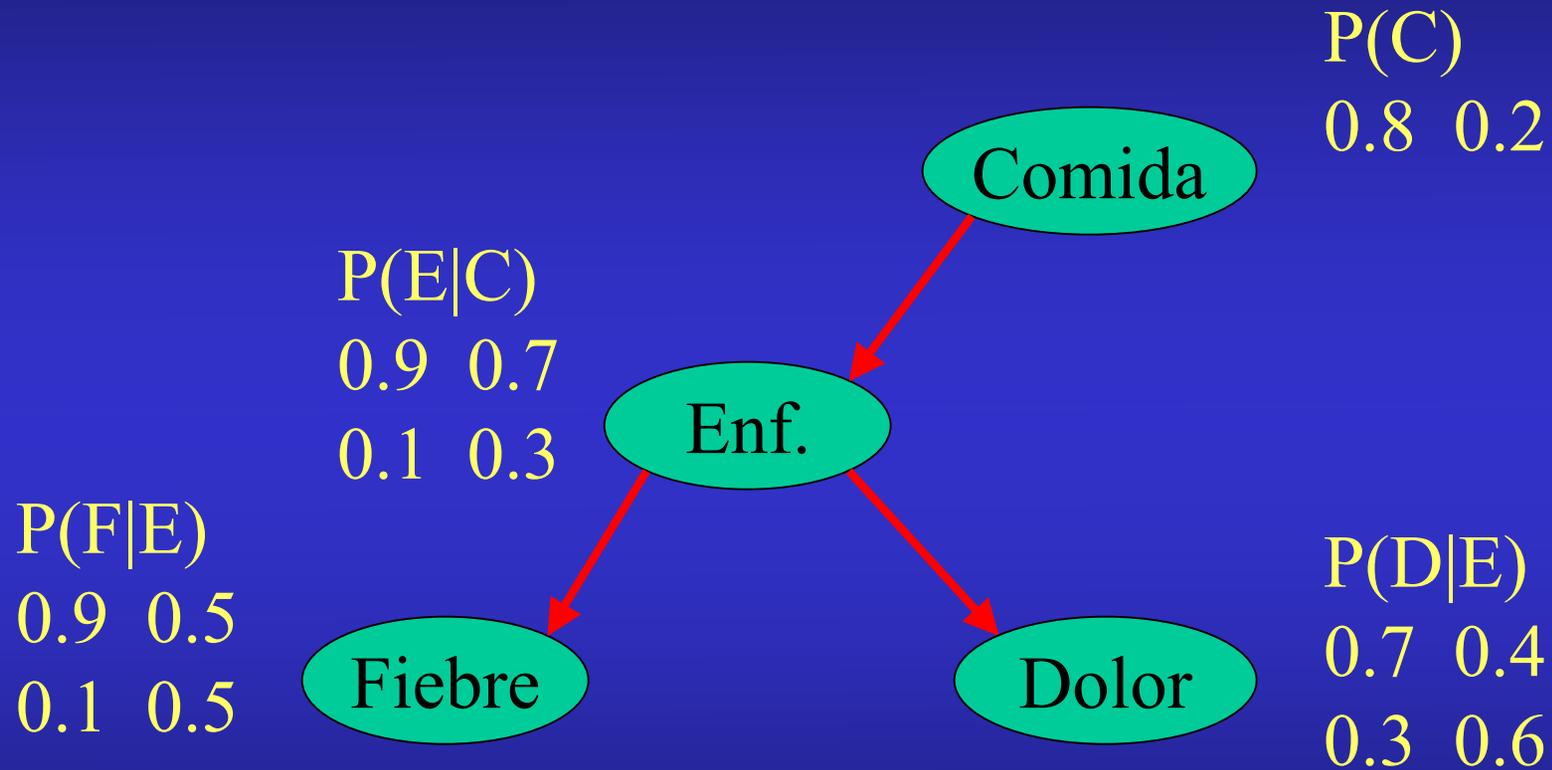
$$\lambda (B_i) = [0, 0, \dots, 1, 0, \dots, 0] \text{ (1 para valor asignado)}$$

$$\pi (B_i) = [0, 0, \dots, 1, 0, \dots, 0] \text{ (1 para valor asignado)}$$

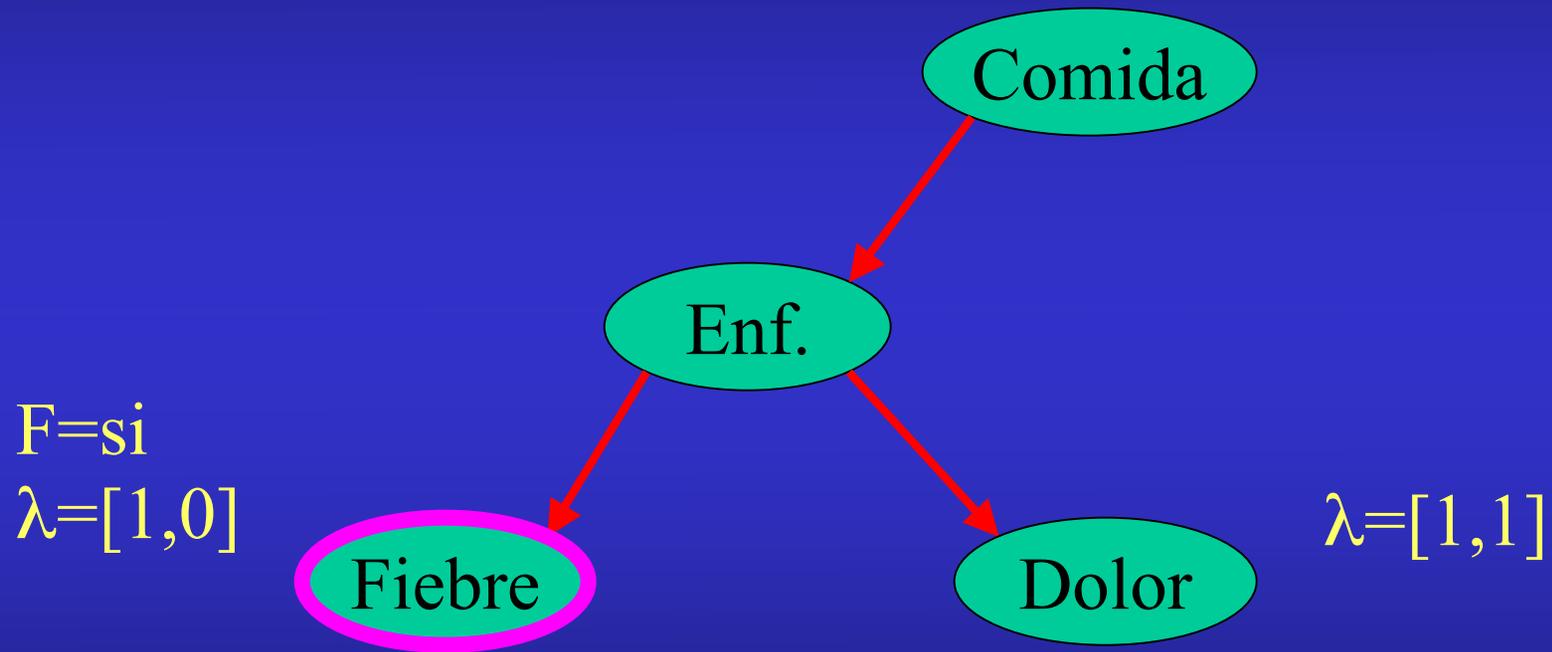
- Nodo raíz no conocido:

$$\pi (A) = P(A), \text{ (probabilidad marginal inicial)}$$

Ejemplo

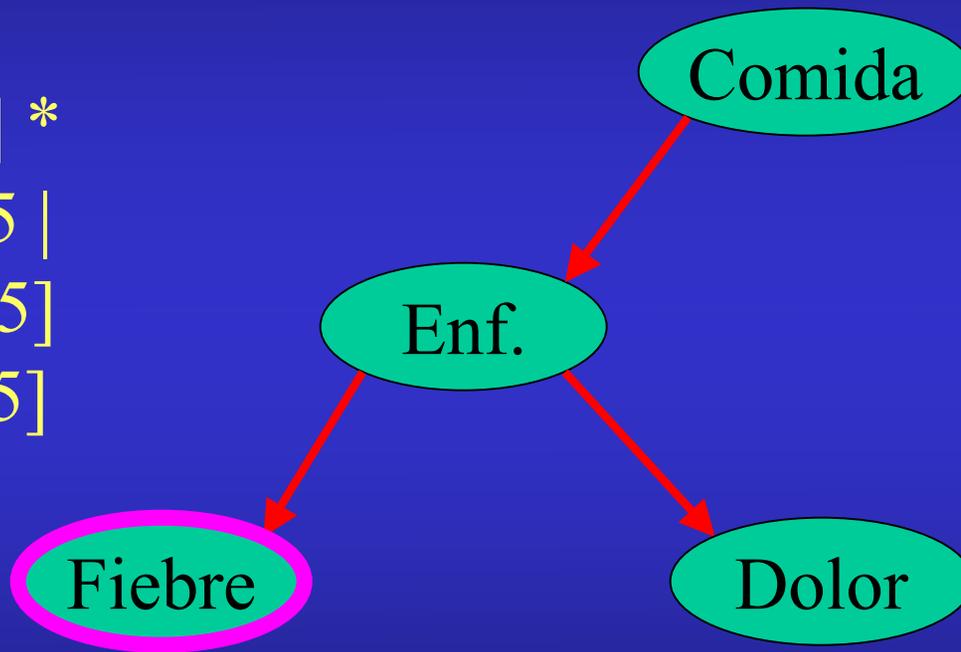


Ejemplo



Ejemplo

$$\lambda_F = [1, 0] * \begin{bmatrix} .9 & .5 \\ .1 & .5 \end{bmatrix} = [.9 \ .5]$$



$$\lambda_D = [1, 1] * \begin{bmatrix} .7 & .4 \\ .3 & .6 \end{bmatrix} = [1 \ 1]$$

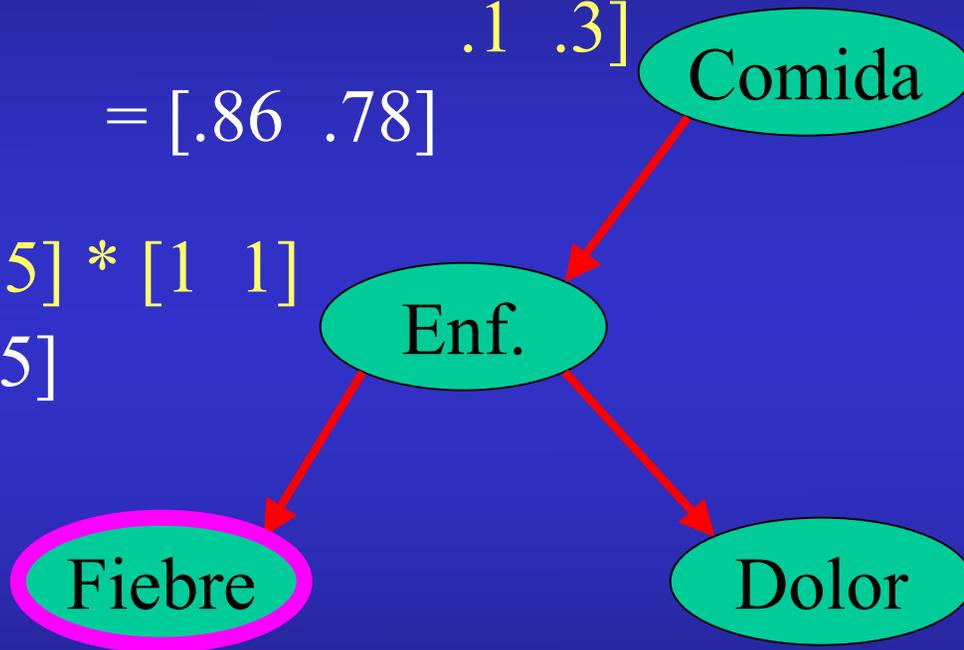
$P(F|E)$
0.9 0.5
0.1 0.5

$P(D|E)$
0.7 0.4
0.3 0.6

Ejemplo

$$\lambda(C) = [.9 \ .5] * \begin{bmatrix} .9 & .7 \\ .1 & .3 \end{bmatrix} \\ = [.86 \ .78]$$

$$\lambda(E) = [.9 \ .5] * [1 \ 1] \\ = [.9 \ .5]$$



P(E C)	
0.9	0.7
0.1	0.3

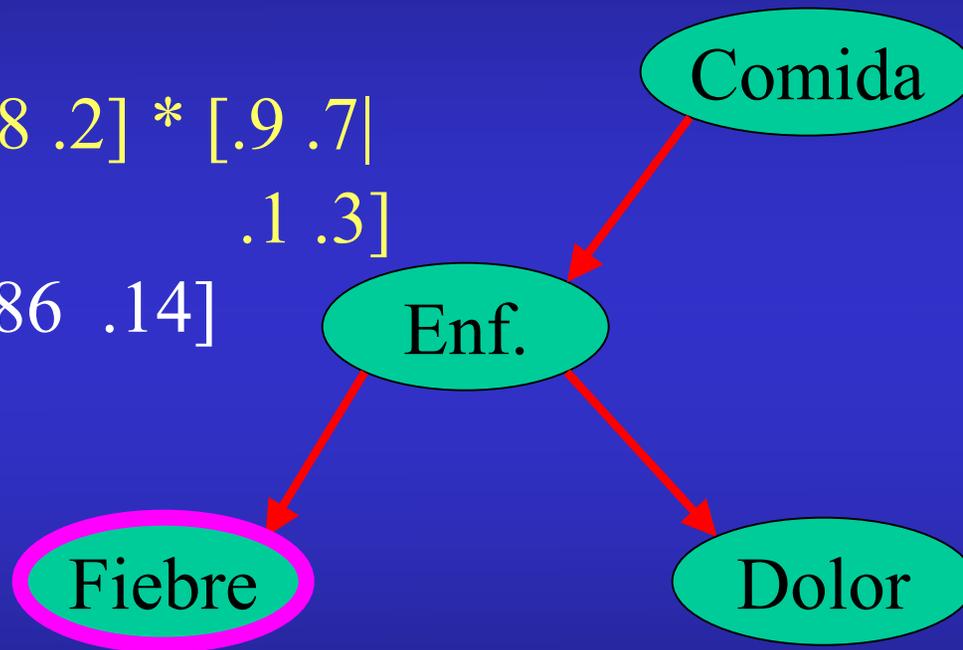
P(F E)	
0.9	0.5
0.1	0.5

P(D E)	
0.7	0.4
0.3	0.6

Ejemplo

$$\pi(C) = [.8 \ .2]$$

$$\begin{aligned} \pi(E) &= [.8 \ .2] * \begin{bmatrix} .9 & .7 \\ .1 & .3 \end{bmatrix} \\ &= [.86 \ .14] \end{aligned}$$



$$P(E|C) \begin{bmatrix} 0.9 & 0.7 \\ 0.1 & 0.3 \end{bmatrix}$$

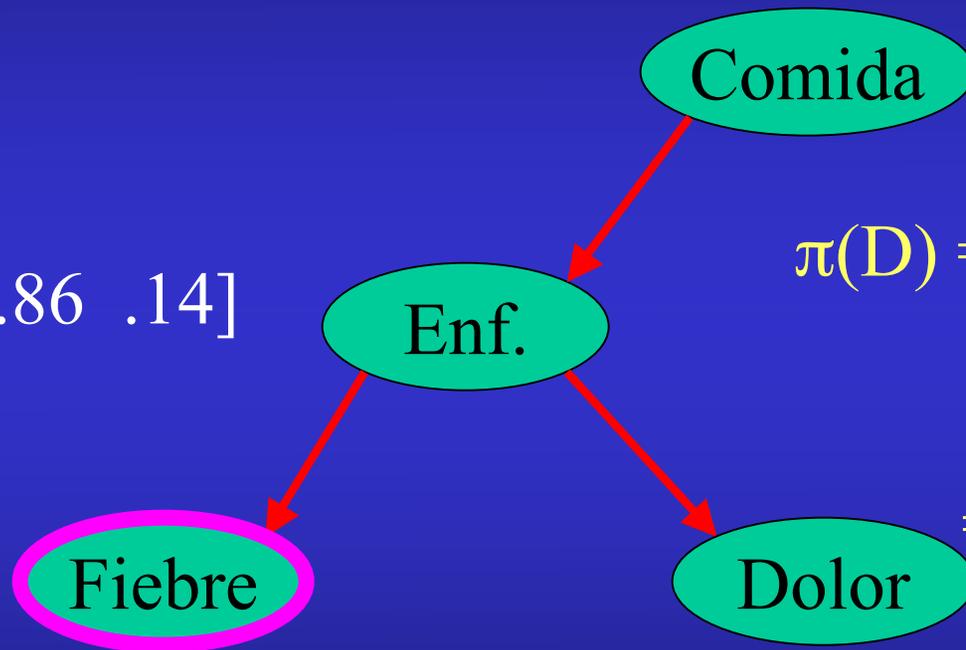
$$P(F|E) \begin{bmatrix} 0.9 & 0.5 \\ 0.1 & 0.5 \end{bmatrix}$$

$$P(D|E) \begin{bmatrix} 0.7 & 0.4 \\ 0.3 & 0.6 \end{bmatrix}$$

Ejemplo

$$\pi(C) = [.8 \ .2]$$

$$\pi(E) = [.86 \ .14]$$



$$\begin{aligned} \pi(D) &= [.86 \ .14] * [.9 \ .5] \\ & \quad [.7 \ .4] \\ & \quad [.3 \ .6] \\ &= [.5698 \ .2742] \end{aligned}$$

$$\begin{array}{l} P(D|E) \\ 0.7 \ 0.4 \\ 0.3 \ 0.6 \end{array}$$

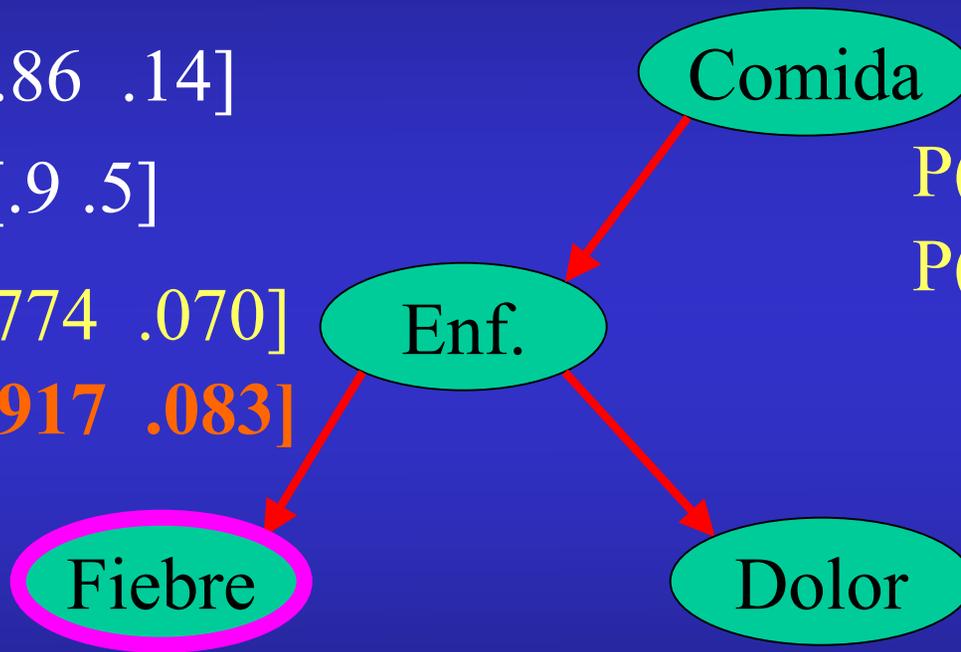
Ejemplo

$$\pi(E) = [.86 \ .14]$$

$$\lambda(E) = [.9 \ .5]$$

$$P(E)=\alpha[.774 \ .070]$$

$$P(E)= [.917 \ .083]$$



$$\pi(C) = [.8 \ .2]$$

$$\lambda(C) = [.86 \ .78]$$

$$P(C)=\alpha[.688 \ .156]$$

$$P(C)= [.815 \ .185]$$

$$\pi(D) = [.57 \ .27]$$

$$\lambda(D)=[1,1]$$

$$P(D)=\alpha[.57 \ .27]$$

$$P(D)= [.67 \ .33]$$

Tarea

- Leer sobre redes bayesianas (capítulo en la página)