

Modelos Gráficos Probabilistas

L. Enrique Sucar

INAOE

Sesión 8:

Redes Bayesianas - Representación

“La probabilidad no es realmente sobre números,
es sobre la estructura del razonamiento”

[G. Shafer]

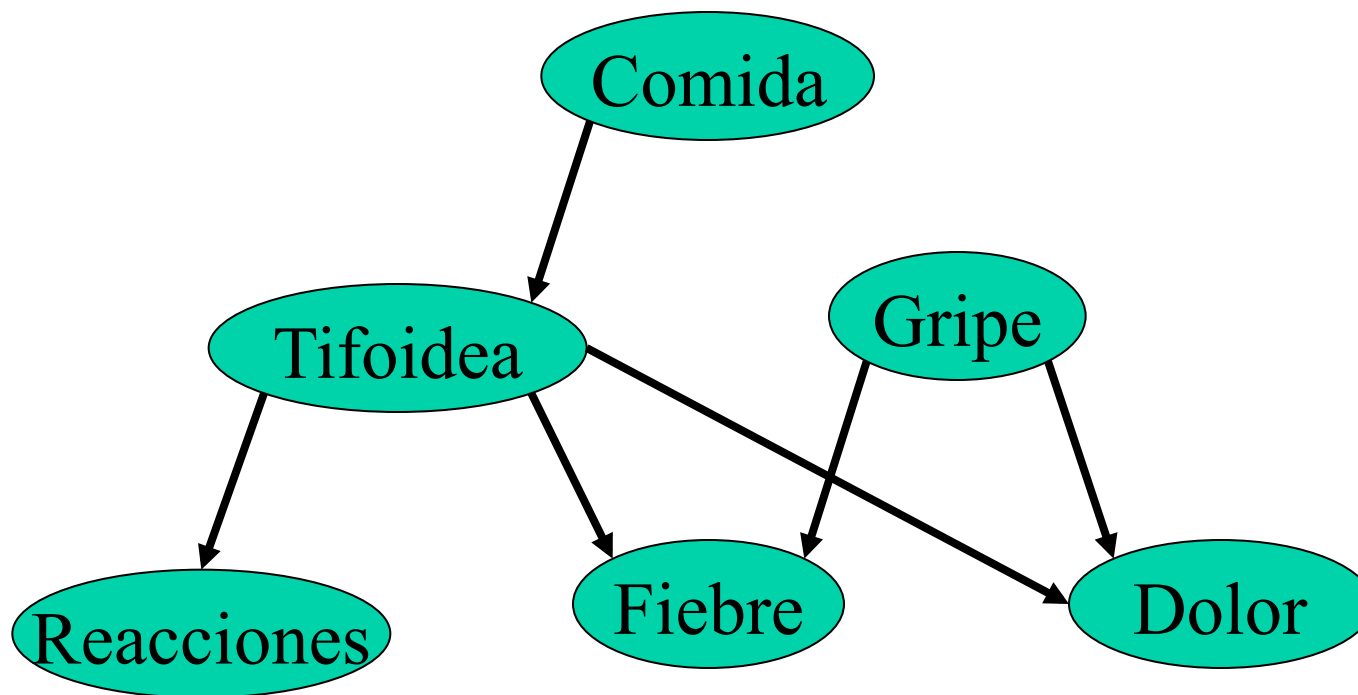
Redes Bayesianas

- Introducción
- Representación estructural
 - Separación – D
 - Correspondencia estructura – distribución de probabilidad (Mapa D, I, P)
 - Axiomas de independencia
- Representación paramétrica
 - Parámetros
 - Modelos canónicos
 - Otras representaciones


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



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:

$$P(Fva | Fv, Fe, Nd, Fb) = P(Fva | Fb)$$

- 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, 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)?

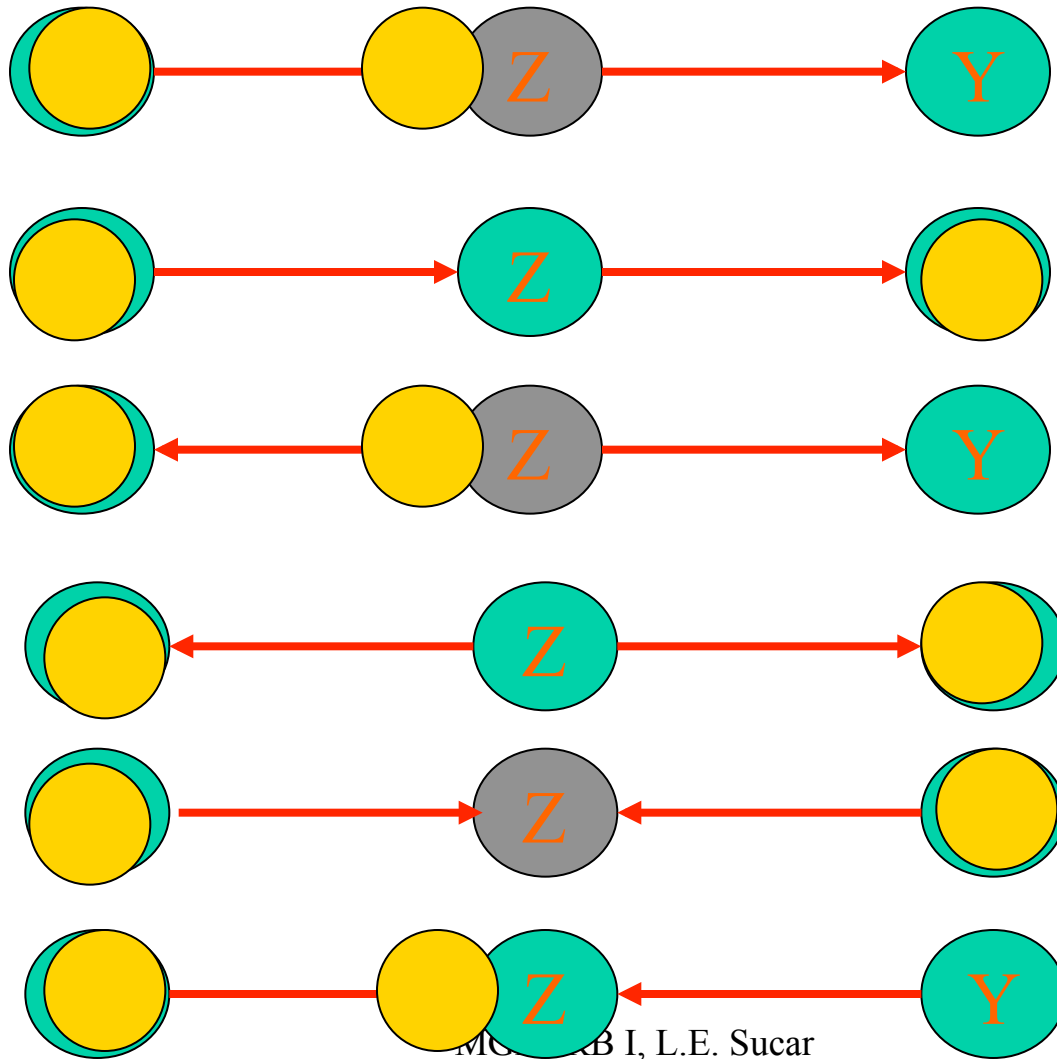
Bayes Ball

- Otra forma de ver si dos conjuntos de variables (X, Z) están separados por otro (Y) es mediante el algoritmo de la “pelota de Bayes”
- Se somborean los nodos en Y y se lanzan pelotas desde todos los nodos en X hacia Z
- Si alguna pelota llega a Z , no son condicionalmente independientes $I(X, Y, Z)$

Bayes Ball

- Las reglas para el paso de las pelotas son:
 - Si el nodo es divergente (casos 1 y 2) y no está sombreado, la pelota pasa
 - Si el nodo es divergente (casos 1 y 2) y está sombreado, la pelota no pasa
 - Si el nodo es convergente (caso 3) y no está sombreado, la pelota no pasa
 - Si el nodo es convergente (caso 3) y está sombreado, la pelota pasa

Bayes ball



Correspondencia Grafo-Modelo

- Dada una distribución de probabilidad o modelo (M) y una representación gráfica de dependencias o grafo (G) debe existir una correspondencia entre las independencias representados en ambos
- Tres tipos básicos - *mapas*

Correspondencia Grafo-Modelo

- Mapa-D: las variables independientes están separadas en el grafo
- Mapa-I: las variables separadas en el grafo son independientes
- Mapa perfecto: mapa-I & mapa-D
- No es siempre posible tener un mapa perfecto (hay distribuciones con relaciones de independencia que no se pueden representar como un GAD)


Correspondencia Grafo-Modelo

- Mapa-I mínimo: las variables separadas en el grafo son independientes y al quitar cualquier arco se destruye esta condición
- Una red bayesiana es un grafo acíclico dirigido (GAD) que corresponde a un mapa-I mínimo de una distribución de probabilidad P

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) ?

Axiomas de Independencia

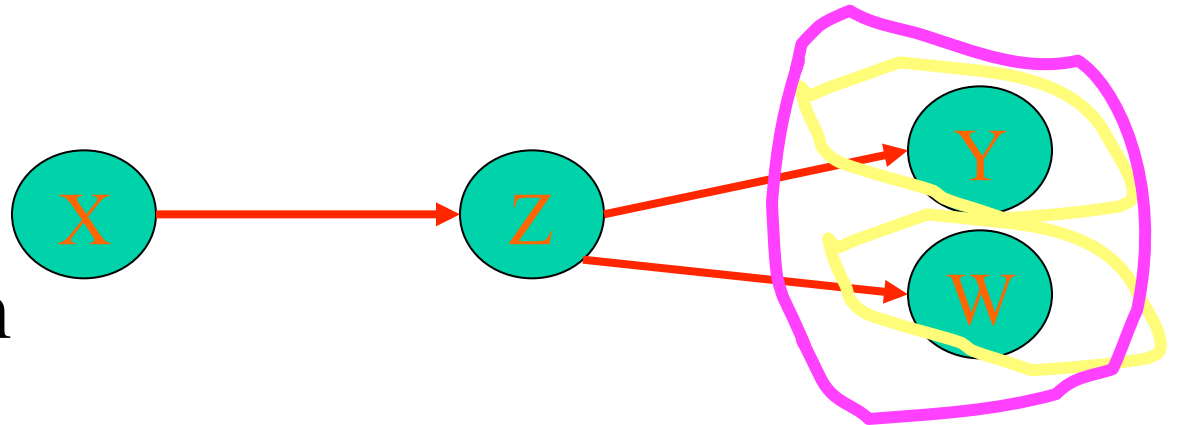
- A partir de ciertas relaciones de independencia se pueden derivar otras, sin necesidad de evaluar las probabilidades
- Para esto se pueden utilizar ciertas reglas. Las reglas básicas se conocen como axiomas de independencia.

Axiomas de Independencia


- Simetría



- Descomposición




- Unión débil




Axiomas de Independencia

- Contracción

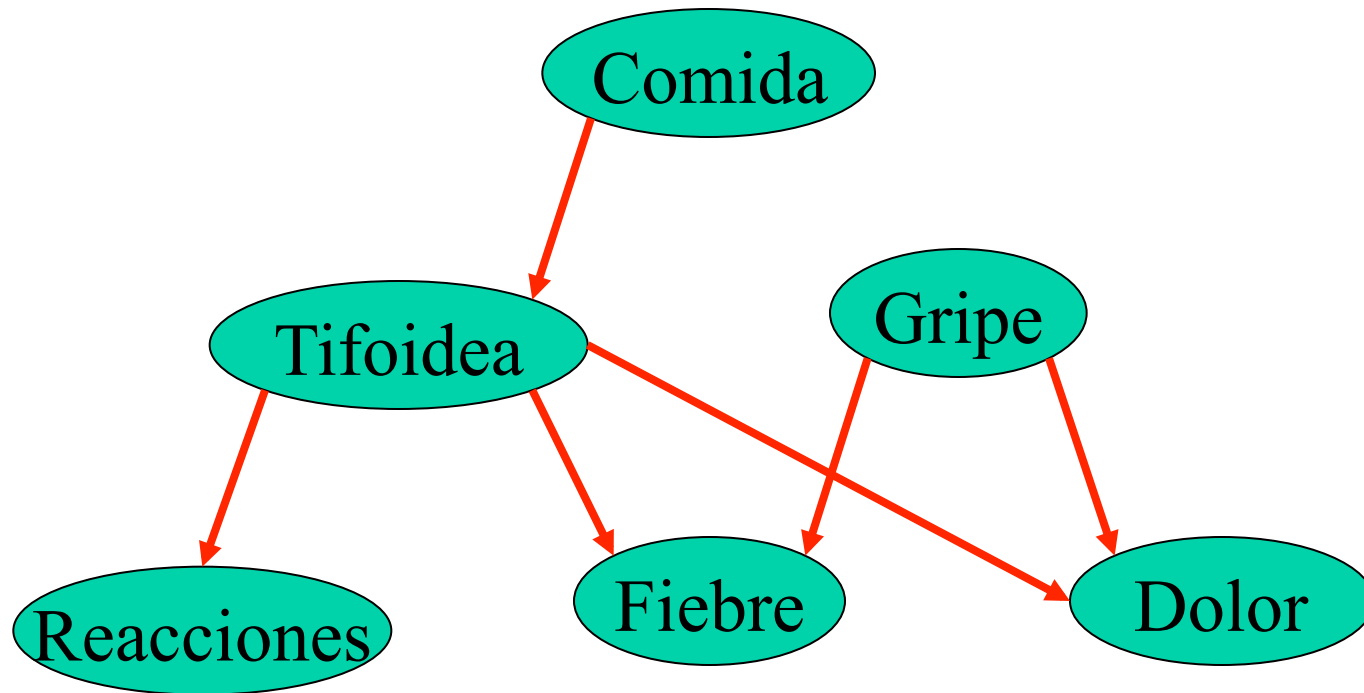


- Intersección

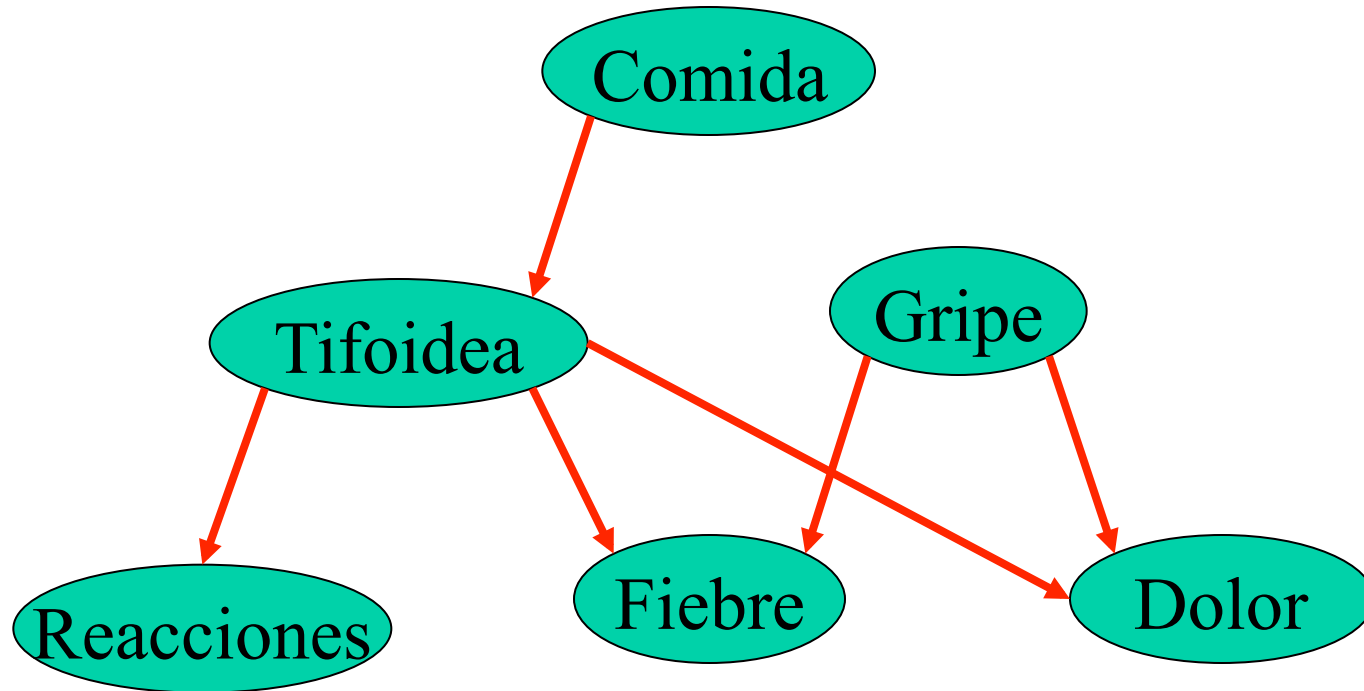


Parámetros

- 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



Ins	Sal
0.2	0.8

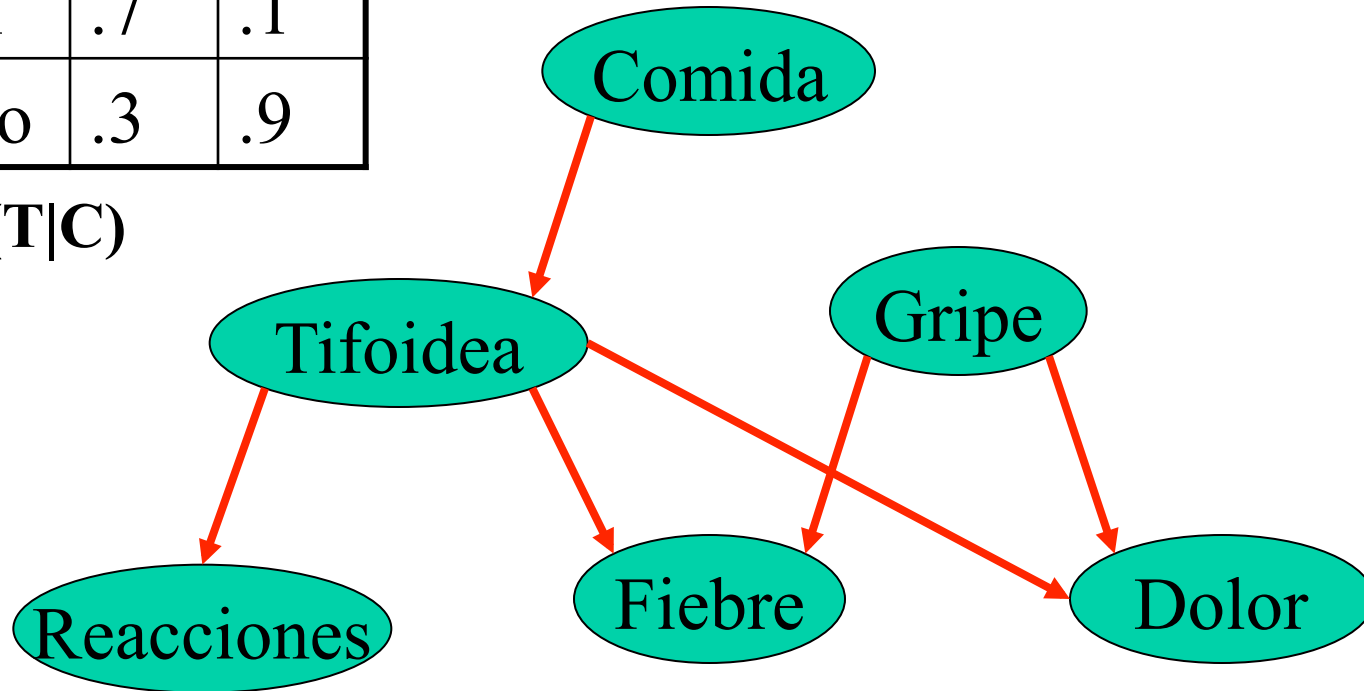


	Ins	Sal
Si	.7	.1
No	.3	.9

$P(T|C)$

$P(C)$

Ins	Sal
0.2	0.8



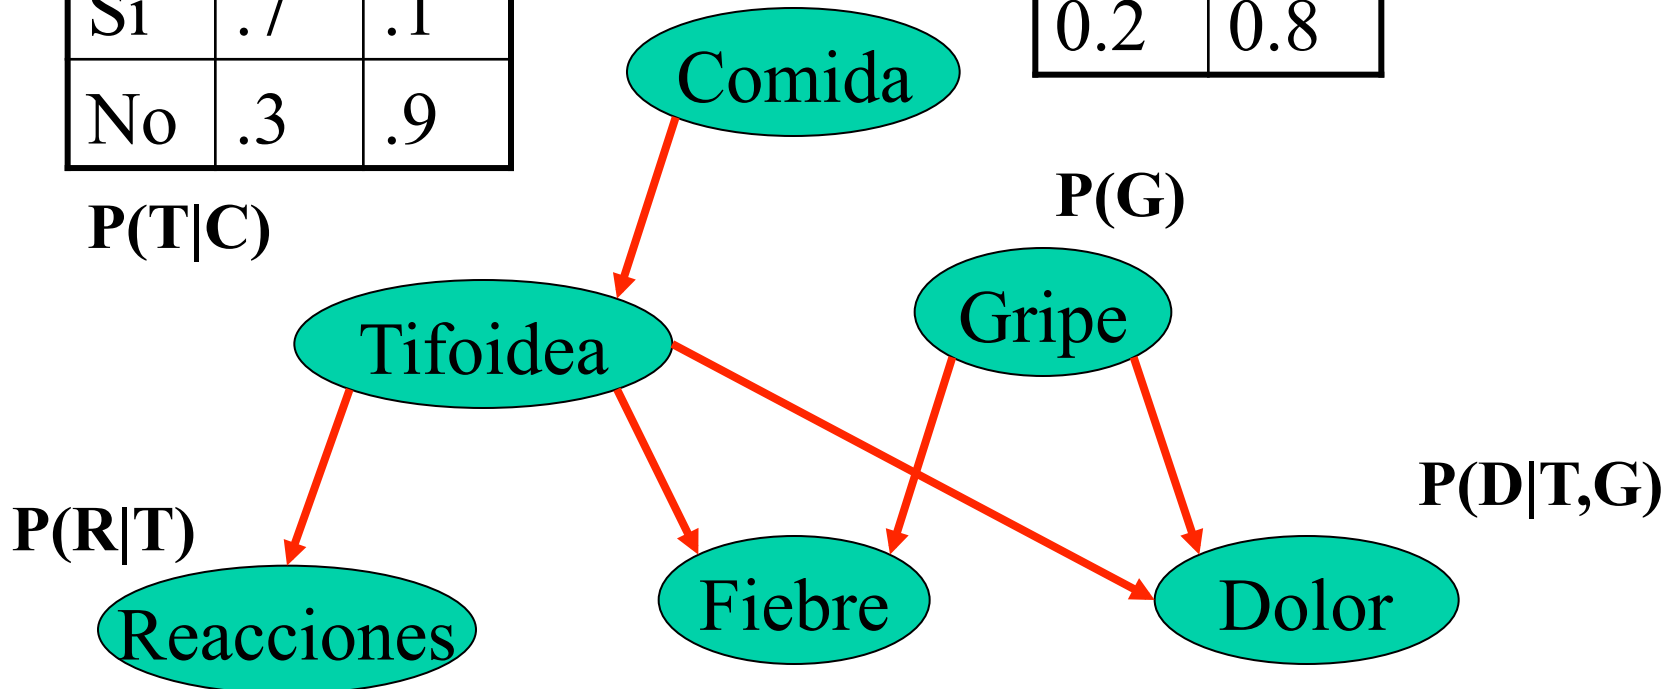
	Ins	Sal
Si	.7	.1
No	.3	.9

$P(T|C)$

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



$$\begin{aligned} & P(A,B,C,D,E,F,G) \\ = & P(G|F,E,D,C,B,A) P(F|E,D,C,B,A) P(E|D,C,B,A) P(D|C,B,A) P(C|B,A) P(B|A) P(A) \\ = & P(G|D) P(F|D,C) P(E|B) P(D|B,A) P(C|A) P(B) P(A) \end{aligned}$$

Especificación Paramétrica

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

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

Ejemplo de una red baysiana

HUGIN

Modelos canónicos

- El tamaño de la tabla de probabilidad condicional crece exponencialmente con el número de padres de un nodo, por lo que puede crecer demasiado
- Una forma de reducir este problema es utilizando ciertos modelos para representar las tablas sin requerir especificar todas las probabilidades – *modelos canónicos*


Modelos canónicos

- Tipos de modelos:
 - Modelo de interacción disjuntiva (*Noisy OR*)
 - Modelo de interacción conjuntiva (*Noisy AND*)
 - Compuerta Max (*Noisy Max gate*)
 - Compuerta Min (*Noisy Min gate*)

Noisy OR

- Se aplica cuando varias “causas” pueden ocasionar un “efecto” c/u por si sola, y la probabilidad del efecto no disminuye si se presentan varias causas
- Se considera que todas las variables son binarias
- Por ejemplo, este modelo se puede aplicar cuando varias enfermedades pueden producir el mismo síntoma

Noisy OR



Noisy OR

- Propiedades:
 - Responsabilidad: el efecto es falso si todas sus posibles causas son falsas
 - Independencia de excepciones: si un efecto es la manifestación de varias causas, los mecanismos que inhiben la ocurrencia del efecto bajo una causa, son independientes de los que lo inhiben bajo otras causas

Noisy OR

- Probabilidades:
 - Probabilidad de que el efecto sea inhibido por la causa i :

$$q_i = P(\neg E \mid C_i)$$

- En base a esto se puede calcular la matriz de probabilidad condicional como:

$$P(E \mid C_1, \dots, C_n) =$$

$$\prod_{C_i=1} q_i, \quad E=0$$

$$1 - \prod_{C_i=1} q_i, \quad E=1$$

Noisy OR

- Ejemplo: 3 causas, $q_1=q_2=q_3=0.1$


$P(E \mid C_1, C_2, C_3)$

C1	0	0	0	0	1	1	1	1
C2	0	0	1	1	0	0	1	1
C3	0	1	0	1	0	1	0	1
E=0	1	.1	.1	.01	.1	.01	.01	.001
E=1	0	.9	.9	.99	.9	.99	.99	.999

Otras representaciones

- Otras formas compactas de representar las tablas de probabilidad condicional:
 - Árboles de decisión
 - Diagramas de decisión
 - Redes neuronales

CPT – árbol de decisión




$P(C|A,B)$

00 01 10 11

0.2 0.5 0.1 0.1

0.8 0.5 0.9 0.9

CPT – diagrama de decisión




$P(C|A,B)$

00 01 10 11

0.2 0.5 0.2 0.5

0.8 0.5 0.8 0.5

CPT – red neuronal



$P(C|A,B)$

00 01 10 11

0.2 0.5 0.1 0.1

0.8 0.5 0.9 0.9

Referencias

- Pearl 88 – Cap. 3
- Neapolitan 90 – Cap. 5
- Koller & Friedman - Cap. 3
- Sucar, Morales, Hoey - Cap. 2
- Sucar, L.E., “Introducción a redes bayesianas”, en Sierra (ed.), Aprendizaje Automático, Pearson, 2008
- F. J. Díez y M. J. Druzdzel. Canonical probabilistic models for knowledge engineering. Technical Report CISIAD-06-01. UNED, Madrid, 2006

Actividades

- Leer capítulo redes bayesianas (en la página)
- Hacer ejercicios de representación de redes bayesianas