

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

$$I(X, Z, Y) \rightarrow I(Y, Z, X)$$




- Descomposición

$$I(X, Z, Y \cup W) \rightarrow I(X, Z, Y) \ \& \ I(X, Z, W)$$



- Unión débil


$$I(X, Z, Y \cup W) \rightarrow I(X, Z \cup W, Y)$$



# Axiomas de Independencia

- Contracción

$$I(X, Z, Y) \& I(X, Z \cup Y, W) \rightarrow I(X, Z, Y \cup W)$$



- Intersección


$$I(X, Z \cup W, Y) \& I(X, Z \cup Y, W) \rightarrow I(X, Z, Y \cup W)$$



# 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



$P(G)$

$P(R|T)$

$P(F|T,G)$

$P(D|T,G)$


	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