

MARTÍN BATISTA - SEMINARIO INFERENCIA CAUSAL

GRAFOS CAUSALES

1.5 – STRUCTURAL CAUSAL MODELS

MODELOS CAUSALES ESTRUCTURALES

▶ SCM (definición):

▶ Dos conjuntos de variables:

▶ **Exógenas** (externas): U

▶ **Endógenas** (internas): V

▶ Un conjunto de funciones $\{f_v : v \in V\}$.


▶ Una función para cada variable endógena definida a partir de las otras.

▶ Ecuaciones estructurales:


▶ $B := f_B(A, U_B)$

▶ $C := f_C(A, B, U_C)$

▶ $D := f_D(A, C, U_D)$



- ▶ $V = \{X, Y, Z\}$, $U = \{U_X, U_Y, U_Z\}$, $F = \{f_X, f_Y, f_Z\}$
- ▶ $f_X: X = U_X$, $f_Y: Y = \frac{X}{3} + U_Y$, $f_Z: Z = \frac{Y}{16} + U_Z$
- ▶ (b) $\mathbb{E}[Z|Y = 3]$?
 - ▶ $\mathbb{E}[Z|Y = 3] = \mathbb{E}\left[\frac{3}{16}\right] + \mathbb{E}[U_Z] = 3/16 \approx 0.19$
- ▶ (c) $\mathbb{E}[Z|X = 3]$?
 - ▶ $\mathbb{E}[Z|X = 3] = \mathbb{E}\left[\left(\frac{3}{3} + U_Y\right)/16\right] + \mathbb{E}[U_Z] = 1/16 \approx 0.06$
- ▶ (d) $\mathbb{E}[Z|X = 1, Y = 3]$?
 - ▶ Al condicionar en $Y = 3$; X y Z están d-separados (más adelante), tenemos el mismo resultado que (b).



EJEMPLO EN R

INTRODUCCIÓN A GRAFOS

FACTORIZACIÓN Y REDES BAYESIANAS

FACTORIZACIÓN Y REDES BAYESIANAS

- ▶ Para modelar la asociación entre variables, nos interesa determinar la distribución conjunta $P(x_1, x_2, \dots, x_n)$.

- ▶ Usando la regla de la cadena podemos factorizar la distribución:

$$P(x_1, x_2, \dots, x_n) = P(x_1) \prod_i P(x_i | x_{i-1}, \dots, x_1)$$

- ▶ Hay un problema con éste enfoque de fuerza bruta:

- ▶ Consideremos $\{x_1, x_2, \dots, x_n\}$ variables binarias.
- ▶ Para codificar $P(X_n = 1 | x_{n-1}, \dots, x_1)$ precisamos 2^{n-1} parámetros.

- ▶ Consideremos el ejemplo para $n = 4$.
- ▶ Esto se vuelve rápidamente intratable.

x_1	x_2	x_3	$P(x_4 x_3, x_2, x_1)$
0	0	0	α_1
0	0	1	α_2
0	1	0	α_3
0	1	1	α_4
1	0	0	α_5
1	0	1	α_6
1	1	0	α_7
1	1	1	α_8


Se requieren $2^3 = 8$ parámetros.

Source: Brady Neal - Introduction to Causal Inference.

REDES BAYESIANAS

- ▶ Podemos simplificar el problema si modelamos dependencias locales.
- ▶ Por ejemplo: Si sospechamos que x_4 depende de x_3 y no de las otras variables, consideramos $P(x_4 | x_3)$ en vez de $P(x_4 | x_3, x_2, x_1)$.
- ▶ Para preservar nuestra cordura, introducimos las redes Bayesianas.
- ▶ Son modelos en base a grafos dirigidos acíclicos que nos permite codificar las dependencias que creemos existen en los datos.
- ▶ Por ejemplo, el grafo de la derecha codifica la relación:

$$P(x_1, x_2, x_3, x_4) = P(x_1)P(x_2 | x_1)P(x_3 | x_2, x_1)P(x_4 | x_3, x_2, x_1)$$



- ▶ Regla de descomposición de productos:
- ▶ La factorización de las redes Bayesianas cumplen (Markov local):


$$P(x_1, x_2, \dots, x_n) = \prod_i P(x_i | \text{pa}_i)$$

- ▶ Dados los padres en un DAG, un nodo X es independiente de todos sus no-descendientes.
- ▶ O sea:

$$P(x_1, x_2, x_3, x_4) = P(x_1)P(x_2 | x_1)P(x_3 | x_2, x_1)P(x_4 | x_3, x_2, x_1)$$

- ▶ Se convierte en:

$$P(x_1, x_2, x_3, x_4) = P(x_1)P(x_2 | x_1)P(x_3 | x_2, x_1)P(x_4 | x_3)$$



UTILIDAD - EJEMPLO

- ▶ Consideremos el modelo:


$$X \rightarrow Y \rightarrow Z \rightarrow W$$

- ▶ Donde:
 - ▶ X : nublado/no-nublado
 - ▶ Y : lluvia/no-lluvia
 - ▶ Z : pavimento húmedo/seco
 - ▶ W : pavimento resbaladizo/no-resbaladizo
- ▶ Que probabilidad hay que:

$$P(\text{nublado, no-lluvia, pavimento seco, pavimento resbaladizo}) = 0.23 ?$$

UTILIDAD - EJEMPLO

$P(\text{nublado, no-lluvia, pavimento seco, pavimento resbaladizo}) = 0.23 ?$



▶ Donde:

▶ X : nublado/no-nublado

▶ Y : lluvia/no-lluvia

▶ Z : pavimento húmedo/seco

▶ W : pavimento resbaladizo/no-resbaladizo

▶ Factorizando:


$P(\text{nublado})P(\text{no-lluvia}|\text{nublado})P(\text{pavimento seco}|\text{no lluvia})P(\text{pavimento resbaladizo}|\text{pavimento seco})$

▶ Podemos estimar, aproximadamente: $0.5 \times 0.75 \times 0.9 \times 0.05 = 0.0169$

GRAFOS CAUSALES




CAUSALIDAD

- ▶ ¿Qué es una causa?
- ▶ Decimos que una variable X es una causa de una variable Y si Y cambia en respuesta a cambios en X .
- ▶ Judea Pearl dice: "*X es causa de Y si Y escucha a X.*"
- ▶ Grafo causal:
 - ▶ Es una red Bayesiana donde los padres son causas directas de los hijos.




X es causa de Y
Y es causa de Z
X no es causa (directa) de Z

ESTRUCTURAS BÁSICAS



CADENAS

- ▶ En las cadenas, si bien X no es causa directa de Z , generalmente (hay casos patológicos e.g. SCM 2.2.4) fluye asociación entre ambas variables.
- ▶ Lo hace mediante la variable de confusión Y
- ▶ X induce cambios en Y que a su vez induce cambios en Z
- ▶ La asociación es simétrica, Z está asociada con X como X está asociada a Z .



CADENAS

- ▶ Si condicionamos respecto a Y , bloqueamos la asociación:

- ▶ $P(x, y, z) = P(x)P(y | x)P(z | y)$ (cadena)

- ▶ $P(x, z | y) = \frac{P(x, y, z)}{P(y)}$ (regla de Bayes)


- ▶ $P(x, z | y) = \frac{P(x)P(y | x)P(z | y)}{P(y)}$ (sustitución)

- ▶ $P(x, z | y) = \frac{P(x, y)}{P(y)}P(z | y)$ (Bayes de nuevo)

- ▶ $P(x, z | y) = P(x | y)P(z | y)$


- ▶ Obtenemos que: $X \perp Z | Y$.

- ▶ X y Z son condicionalmente independientes. ¿Tiene sentido?




CADENAS - EJEMPLO - SCM 2.2.1-3

- ▶ Las variables X, Y, Z son binarias.
- ▶ Al condicionar en Y estamos considerando los casos $Y = 0$ e $Y = 1$.
- ▶ Consideramos el caso $Y = 0$
- ▶ Al cambiar los valores de X simultáneamente cambian los valores de U_Y de forma que la Y se mantenga en $Y = 0$.
- ▶ Z no logra escuchar ningún cambio en Y inducido por X .
- ▶ O sea: por la propiedad de Markov local, cada variable depende de los valores de sus padres.
- ▶ Si condicionamos sobre los mismos, se vuelven independientes.




BIFURCACIONES

- ▶ Ocurre lo mismo con las bifurcaciones. Comparten las mismas independencias que las cadenas.



En las bifurcaciones también fluye asociación entre las variables.




Nuevamente condicionando, se puede bloquear.

INMORALIDADES

- ▶ Con las inmoralidades la historia es diferente.
- ▶ X y Z simplemente son eventos no relacionados que contribuyen a un efecto común en Y .
- ▶ O sea: $X \perp Z$

$$\begin{aligned} P(x, z) &= \sum_y P(x, y, z) \\ &= \sum_y P(x)P(z)P(y | x, z) \\ &= P(x)P(z) \sum_y P(y | x, z) \\ &= P(x)P(z) \end{aligned}$$


- ▶ A la variable Y le llamamos **collider**.



En las inmoralidades no fluye asociación entre X y Z

INMORALIDADES

- ▶ Si condicionamos en una variable collider, permitimos el pasaje del flujo de asociación.
- ▶ Éste fenómeno se le conoce como la paradoja de Berkson. (https://en.wikipedia.org/wiki/Berkson%27s_paradox)
- ▶ Cuando condicionamos en Y estamos filtrando los valores de la variable.
- ▶ Al variar X , necesariamente tiene que variar Z para mantener a Y en los valores filtrados que habíamos condicionado.
- ▶ Condicionar en los descendientes de un collider también permite el flujo de asociación.




EJEMPLO - MONTY HALL

- ▶ El problema de Monty Hall:
 - ▶ Hay 3 puertas.
 - ▶ En una hay un auto.
 - ▶ En las otras dos hay una cabra.
- ▶ Elegís una puerta.
- ▶ El anfitrión abre otra puerta, revelando una cabra.
- ▶ Te dan la oportunidad de cambiar tu decisión original. ¿Lo haces?



EJEMPLO - MONTY HALL

- ▶ Nuestra probabilidad de acierto original era $1/3$.
- ▶ Luego de que Monty abre la puerta y revela una cabra, cambiar de puerta eleva la probabilidad de ganar a $2/3$.
- ▶ Al condicionar sobre la puerta (Monty revela la cabra) fluye información entre los nodos padres.




D-SEPARACIÓN

- ▶ A un camino entre nodos X e Y es **bloqueado** por un conjunto (puede ser vacío) de condicionamiento Z si:
 - ▶ En el camino hay una cadena $\dots \rightarrow W \rightarrow \dots$ o una bifurcación $\dots \leftarrow W \rightarrow \dots$, donde $W \in Z$
 - ▶ Existe un collider W en el camino que no es condicionado ($W \notin Z$) y ninguno de sus descendientes son condicionados ($de(W) \notin Z$)
- ▶ Un camino **no-bloqueado** es el complemento. La asociación fluye a través de los caminos no-bloqueados y no lo hace a través de los bloqueados.
- ▶ Dos conjuntos de nodos X e Y están **d-separados** por un conjunto de nodos Z si todos los caminos entre cualquier nodo de X y cualquier nodo de Y están bloqueados por Z .

D-SEPARACIÓN - EJEMPLOS

- ▶ Están T y Y d-separados por:
 - ▶ ¿El conjunto vacío?
 - ▶ ¿ W_2 ?
 - ▶ ¿ $\{W_2, M_1\}$?
 - ▶ ¿ $\{W_1, M_2\}$?
 - ▶ ¿ $\{W_1, M_2, X_2\}$?
 - ▶ ¿ $\{W_1, M_2, X_2, X_3\}$?



Source: Brady Neal - *Introduction to Causal Inference*

D-SEPARACIÓN - MOTIVACIÓN

- ▶ La d-separación implica que la asociación es causalidad.
- ▶ Si dos variables T e Y están d-separadas, entonces no fluye asociación entre ellas que no sea causal.
- ▶ Visto de otra forma todo el efecto causal que sale de T llega a Y y no hay asociaciones de confusión entre ellas.

