

Cap. 2: 2.7-2.9

Pearl, Causality, 2nd Edition - Chapter 2: A
Theory of Inferred Causation

Claudio López

Instituto Nacional de Astrofísica, Óptica y Electrónica

1. 2.7 Criterio local de relación causal
2. 2.8 Causa no temporal y tiempo estadístico
3. 2.9 Conclusiones

2.7 Criterio local de relación causal

El grafo dado por IC^* es un grafo parcialmente dirigido. Se tiene 4 tipos de aristas:

- 1) Las unidireccionales: denotan causa genuina.
- 2) Las unidireccionales sin marcar: denotan causa potencial.
- 3) Las bidireccionales: denotan falsa asociación.
- 4) Las no direccionales: son relaciones indeterminadas.

Se presentan las definiciones de causa potencial y genuina dadas por el algoritmo IC^* .

- Estas definiciones necesitan una 3ra variable Z que exhiba el
- patrón de dependencia entre X y Y .
- Se trabaja bajo el paradigma de "sin manipulación no hay causa".
- Z es una variable de control y esta es extraída de los datos.


Definición 2.7.1 (Causa Potencial)

Una variable X tiene una influencia causal potencial sobre otra variable Y (que deducible de \hat{p}) si se cumplen las siguientes condiciones:

1. X y Y son dependientes en cualquier contexto.
2. Existe una variable Z y un contexto S tal que:
 - i) X y Z son independientes dado S ($X \perp\!\!\!\perp Z | S$)
 - ii) Z y Y son dependientes dado S ($Z \not\perp\!\!\!\perp Y | S$)

Nota: "Contexto" se refiere a un conjunto de variables ligadas a valores específicos.

Definición 2.7.1 (Causa Potencial)



Por ejemplo, la variable b cualifica como una causa potencial de d . Dada la variable $Z=c$, b es independiente de b en el contexto $S=a$. Igualmente c cualifica como causa potencial de d (con $Z=b$ y $S=a$). Pero no cualifican como causas genuinas de d .


La definición descalifica a d como causa potencial de b o c . También excluye a X ser causa potencial de si misma o de alguna otra que funcionalmente determine X .

Definición 2.7.2 (Causa Genuina)

Una variable X tiene influencia causal genuina sobre otra variable Y si existe una variable Z tal que:

1. X y Y son dependientes en cualquier contexto y existe un contexto S que satisface:
 - i) Z es una causa potencial de X (Def. 2.7.1)
 - ii) Z y Y son dependientes dado S ($Z \not\perp\!\!\!\perp Y | S$)
 - iii) Z y Y son independientes dado $S \cup X$ ($Z \perp\!\!\!\perp Y | S \cup X$)
- o
2. X y Y están en el cierre transitivo de la relación definida en el criterio 1.

Definición 2.7.2 (Causa Genuina)



Las condiciones i)-iii) se reflejan en la figura con: $X=d$, $Y=e$, $Z=b$ y $S=\emptyset$. La destrucción de la dependencia entre b y e a través de d puede no atribuirse a asociación falsa entre d y e ; La influencia causal genuina es solo la explicación, como se muestra en las estructuras 2.4:




Figure 2.4 Latent structures equivalent to those of Figure 2.3(a).

Definición 2.7.3 (Falsas Asociaciones)

Dos variables X y Y están asociadas falsamente si ellas son dependientes en algún contexto y existen otras dos variables (Z_1 y Z_2) y dos contextos (S_1 y S_2) tal que:

1. Z_1 y X son dependientes dado S_1 ($Z_1 \not\perp\!\!\!\perp X|S_1$)
2. Z_1 y Y son independientes dado S_1 ($Z_1 \perp\!\!\!\perp Y|S_1$)
3. Z_2 y Y son dependientes dado S_2 ($Z_2 \not\perp\!\!\!\perp Y|S_2$)
4. Z_2 y X son independientes dado S_2 ($Z_2 \perp\!\!\!\perp X|S_2$)


La condición 1 y 2 usan a Z_1 y S_1 para descalificar a Y como causa de X . Paralela a la condición (i)-(ii) de la Def. 2.7.1. La condición 3 y 4 usan a Z_2 y S_2 para descalifican a X como causa de Y . Esto hace que la única explicación de la causa común latente de la dependencia entre X y Y sea de la siguiente forma: $Z_1 \rightarrow X \leftrightarrow Y \leftarrow Z_2$.

Definición 2.7.4 (Causa genuina con información temporal)

Una variable X tiene una influencia causal sobre Y si hay una tercera variable Z y un contexto S , ambas ocurriendo antes que X , tan que:

1. $(Z \not\perp\!\!\!\perp Y | S)$
2. $(Z \perp\!\!\!\perp Y | S \cup X)$

Se basa en la idea de la definición 2.7.2, excepto que la precedencia temporal es ahora usada para establecer a Z como causa potencial de X .




(a)

Definición 2.7.5 (Falsa asociación con información temporal)

Dos variables X y Y son falsamente asociadas si ellas son dependientes en algún contexto S , si X precede a Y y si existe una variable Z que satisfice:

1. $(Z \perp\!\!\!\perp Y | S)$
2. $(Z \not\perp\!\!\!\perp X | S)$ Nota: $Z \rightarrow X$ así S no influencia



Aquí la dependencia entre X y Y no puede atribuirse a una conexión causal entre las dos, porque tal conexión podría implicar dependencia entre Z y Y y se rompe la regla 1.

Ahora bien esto establece para el algoritmo IC*

X no es consecuencia de Y (Def. 2.7.1)

Z no es consecuencia de X (Def. 2.7.2)

y con Def. 2.7.3 establece la influencia causal entre X y Y, por lo tanto la asociación falsa son la única explicación para su dependencia.

El planteamiento de relación causal no temporal plantea preguntas filosóficas acerca de la temporalidad y la explicación causal.

¿Tener $X \rightarrow Y$ (por Def. 2.7.2 y 2.7.4) puedes causar un choque temporal de información?. 2.7.4 se establece bajo fuertes intuiciones sobre el aspecto estadístico de las relaciones causales.

Pero ¿Por qué las orientaciones determinadas únicamente por dependencias estadísticas tienen que ver con el flujo del tiempo?

2.8 Causa no temporal y tiempo estadístico

2.8 Causa no temporal y tiempo estadístico

La explicación causal satisface 2 expectativas: -Temporal: este aspecto es representado por el entendimiento que una causa podría preceder este efecto. -Estadística: este aspecto espera una explicación completa causal para filtrar sus diversos efectos (osea hacer que los efectos sean condicionalmente independientes).

Debido a la coexistencia incomparable de estas dos expectativas a través de observaciones científicas implican que las estadísticas de Los fenómenos naturales deben exhibir algún sesgo temporal básico. De hecho, a menudo nos encontramos con Fenómeno donde el conocimiento de un estado presente hace que las variables del estado futuro. condicionalmente independiente:

$$X_t = \alpha X_{t-1} + \beta Y_{t-1} + e_t$$

$$Y_t = \lambda X_{t-1} + \delta Y_{t-1+n_t}(1)$$

Una manera de formular este sesgo es por la noción de tiempo estadístico.

Definición 2.8.1 Tiempo estadístico

Dada una distribución empírica P , un tiempo estadístico P es un orden de variables que esta de acuerdo con al menos una estructura mínima causal consistente con P .

un proceso de cadena escalar de Markov tiene muchos tiempos estadísticos:

- Uno coincidiendo con el tiempo físico.
- otro opuesto a éste.
- y otros que corresponden a órdenes que concuerdan con cualquier orientación de la cadena de Markov lejos de uno de los nodos (elegido arbitrariamente como raíz).

El algoritmo IC* identifica rápidamente las causas genuinas del ejemplo anterior.

Conjetura 2.8.2 (Sesgo Temporal)

En el fenómeno más natural, el tiempo físico coincide con al menos un tiempo estadístico.

El sesgo temporal va a depender del lenguaje que se elija para representar. Por ejemplo en el ejemplo anterior se puede escribir usando una transformación lineal:

$$X'_t = aX_t + bY_t$$

$$Y'_t = cX_t + dY_t(2)$$

La segmentación no puede expresar el sesgo temporal por el ruido (n_t y e_t) pero al expresarlo de otra forma (lenguaje) X' y Y' se hacen contrarios al tiempo físico.

Haciendo que X' y Y' sean condicionalmente independientes dado sus valores futuros X'_{t+1} y Y'_{t+1} en lugar de sus valores pasados.

2.9 Conclusiones

¿Qué tan seguras son las relaciones causales inferidas por el algoritmo de IC o por el TETRAD o los métodos bayesianos?

Esto se podría replantear a otra pregunta:

¿Qué tan seguras son nuestras predicciones cuando reconocemos objetos tridimensionales por su sombras bidimensionales, o de las imágenes bidimensionales en las que se reflejan los objetos nuestras retinas?

no es absolutamente seguro, pero es lo suficientemente bueno como para distinguir un árbol de un casa y lo suficientemente bueno para hacer inferencias útiles sin tener que tocar todos los objetos físicos que vemos.

2.9 Conclusiones

Esto solo puede ser determinado por experimentos una vez que entendemos la lógica detrás de las pistas disponibles y una vez que aprendemos a poner estas piezas Pistas juntas coherentemente en grandes programas que abordan problemas de la vida real.

Por lo tanto, los modelos causales deben ser elegidos por un criterio que desafíe su estabilidad frente a las condiciones cambiantes, y éstas se muestran en los datos en forma de variables de control virtuales.

Así pues, los patrones de dependencia identificados por las definiciones 2.7.1-2.7.4 constituyen islas de estabilidad, así como pruebas de validación virtuales para modelos causales.

Sería interesante examinar si estas críticas, cuando se incorporan a los programas existentes de aprendizaje automático y de minería de datos, mejorarían la estabilidad de las relaciones descubiertas por tales programas.