



THE WORLD BANK



Sesión Técnica I Inferencia Causal

Claudio Ferraz

Managua, 3 Marzo 2008

Human Development
Network

Latin American and
the Caribbean Region

Finance, Private Sector,
and Infrastructure
Department

World Bank Institute
Evaluation Group

Justificación

- Las preguntas de investigación que motivan la mayoría de los estudios en las ciencias de la salud son de naturaleza causal.
- Por ejemplo:
 - ¿Cuál es la eficacia de un medicamento en una población dada?
 - ¿Qué fracción de muertes de una enfermedad dada podrían haberse evitado por un tratamiento o política dada?

Justificación

- Las preguntas empíricas más difíciles en economía también involucran relaciones causa-efecto:
 - ¿La descentralización de las escuelas mejora la calidad de la educación?
 - ¿Un año de capacitación *causa* mayores ingresos?
 - ¿Las transferencias condicionadas mejoran la salud de niños?

Justificación

El interés en estas preguntas está motivado por:

- ❑ Preocupaciones de política

Ej. ¿ Los programas públicos reducen la pobreza?

- ❑ Consideraciones teóricas

- ❑ Problemas que enfrentan los tomadores de decisiones.

Intuición del problema: un ejemplo hipotético

- Un programa de transferencias monetarias condicionadas para mujeres embarazadas
 - Se someten a controles médicos periódicos
 - Se refuerza la alimentación
 - Se realizan reuniones informativas sobre riesgos de fumar y consumir alcohol durante el embarazo

- La pregunta es: el programa tiene algún impacto sobre el peso del niño al nacer?
 - Cuales son los canales de impacto? Discusión

Transferencias y peso al nacer

- Asuma que tiene datos sobre mujeres en un pueblo con TMC, y sobre mujeres en un pueblo vecino sin TMC

| Y = promedio del peso al nacer, en gramos | | | | |
|---|-----------------|-----------------|------------|------------------|
| | Mujeres con TMC | Mujeres sin TMC | Diferencia | Doble Difference |
| | Pueblo con TMC | Pueblo vecino | | |
| Antes del inicio de las TMC | ? | ? | | |
| Después de que se iniciaron las TMC | 3,250 | 3,100 | 150 | ? |
| Asuma: las diferencias son significativas | | | | |

Transferencias y peso al nacer

- Datos: personas en el programa y personas sin programa, pueblo vecino, Y datos antes del programa

| Y = promedio del peso al nacer, en gramos | | | | |
|---|--------------------|--------------------|------------|---------------------|
| | Mujeres con TMC | Mujeres sin TMC | Diferencia | Doble Diferencia |
| | Pueblo con TMC | Pueblo vecino | | |
| Antes del inicio de las TMC | 3,025 | 2,840 | 185 | |
| Después de que se iniciaron las TMC | 3,250 | 3,100 | 150 | ? |
| Asuma: las diferencias son significativas | | | | |

Transferencias y peso al nacer

- Datos: personas en el programa y personas sin programa a través de una lotería

| Y = promedio del peso al nacer, en gramos | | | | |
|--|-----------------|-----------------|------------|------------------|
| | Mujeres con TMC | Mujeres sin TMC | Diferencia | Doble Diferencia |
| | Pueblo con TMC | Pueblo vecino | | |
| Antes del inicio de las TMC | 3,025 | 2,840 | 185 | |
| Después de que se iniciaron las TMC | 3,250 | 3,100 | 150 | -35 |
| | Mujeres con TMC | Mujeres sin TMC | Diferencia | Doble Diferencia |
| | por loteria | por loteria | | |
| Antes del inicio de las TMC | 3,028 | 3,028 | 0 | |
| Después de que se iniciaron las TMC | 3,250 | 3,105 | 145 | 145 |
| Asuma: las diferencias son significativas | | | | |

Análisis Causal

- El objetivo del análisis estadístico estándar, típicamente probabilidad y otras técnicas de estimación, es inferir parámetros de una distribución, a partir de muestras obtenidas de esa distribución.

- Con la ayuda de tales parámetros, uno puede:
 1. Inferir asociación entre variables,
 2. Estimar la probabilidad de eventos pasados y futuros,
 3. Así como actualizar la probabilidad de eventos a la luz de nueva evidencia o nuevas mediciones.

Análisis Causal

- ❑ Estas tareas pueden llevarse a cabo adecuadamente por el análisis estadístico estándar, si las condiciones experimentales se mantienen.
- ❑ El análisis causal va un paso adelante:
 - Su objetivo es inferir aspectos del proceso de generación de datos.
 - Con la ayuda de tales aspectos, uno puede deducir no solamente la probabilidad de eventos bajo condiciones estáticas, sino también la dinámica de eventos bajo condiciones cambiantes.

Análisis Causal

- Esta capacidad incluye:
 1. Predecir los efectos de intervenciones
 2. Predecir los efectos de cambios espontáneos
 3. Identificar las causas de eventos reportados

- Esta distinción implica que los conceptos causales y de asociación no se mezclan.

Análisis Causal

La palabra *causa* no está en el vocabulario de la teoría de probabilidad estándar.

- Toda teoría de probabilidad nos permite decir que dos eventos están mutuamente *correlacionados*, o son dependientes – lo que significa que, si encontramos uno, podemos esperar encontrar el otro.
- Los científicos que buscan explicaciones causales para fenómenos complejos o racionales para decisiones políticas deben, por tanto, suplir el término de probabilidad con un vocabulario para *causalidad*.

Análisis Causal

Se han propuesto dos términos para causalidad :

1. Structural equation modeling (ESM)
(Haavelmo 1943)
2. The Neyman-Rubin potential outcome model
(RCM)
(Neyman, 1923; Rubin, 1974)

Modelo Causal de Rubin

- Define a la población por la letra U .
Cada unidad en U es denotada por u .
- Para cada $u \in U$, hay asociado un valor $Y(u)$ de la variable de interés Y , la cual llamamos variable de respuesta.
- Sea A una segunda variable definida en U .
Llamamos a A un atributo de las unidades en U .

- ❑ La idea clave es el *potencial* para exponer o no cada unidad a la acción de una causa:
- ❑ Cada unidad tiene que ser potencialmente expuesta a cualquiera de las causas.
- ❑ Así, Rubin **toma** la posición de que las causas son acciones que podrían ser tratamientos en experimentos hipotéticos.
- ❑ Un atributo no puede ser una causa en un experimento, porque la idea de *exposición potencial* no aplica a éste.

- Por simplicidad, asumimos que hay solo 2 causas o nivel de tratamiento.
- Sea D una variable que indica la causa a la cual cada unidad en U es expuesta:

$$D = \begin{cases} t & \text{si la unidad } u \text{ es expuesta a tratamiento} \\ c & \text{si la unidad } u \text{ es expuesta a control} \end{cases}$$

- En un estudio controlado, D es construido por el experimentador.
- En un estudio sin control, D es determinado por factores que están más allá del control del experimentador.

- ❑ Los valores de Y son potencialmente afectados por la causa particular, t o c , a la cual la unidad es expuesta.
- ❑ Así, necesitamos dos variables de respuesta:

$$Y_t(u), Y_c(u)$$

- ❑ $Y_t(u)$ es el valor de la respuesta que sería observada si la unidad u fuera expuesta a t
- ❑ $Y_c(u)$ es el valor que sería observado en la misma unidad u si ésta fuera expuesta a c .

Alternativamente, D se puede expresar como una variable binaria:

$$D = \begin{cases} 0 & \text{si la unidad } u \text{ es expuesta a tratamiento} \\ 1 & \text{si la unidad } u \text{ es expuesta a control} \end{cases}$$

Entonces,

$Y_1(u)$ es el resultado si la unidad u es expuesta a tratamiento

$Y_0(u)$ es el resultado si la unidad u es expuesta a control

Entonces, el resultado de cada individuo puede ser escrito como:

$$Y(u) = DY_1(u) + (1 - D)Y_0(u)$$

Definition: Para cada unidad tratada u , el tratamiento causa

$$d_u = Y_1(u) - Y_0(u)$$

- Esta definición de un efecto causal asume que el estado de tratamiento de un individuo no afecta los resultados potenciales de otros individuos.
- **Problema Fundamental de Inferencia Causal:**
Es imposible observar el valor de $Y_1(u)$ y $Y_0(u)$ en la misma unidad u , por lo tanto, es imposible observar el efecto de t en u .
- Es decir: No podemos inferir el efecto de tratamiento por que no tenemos la evidencia *contrafactual*.
¿Qué hubiera sucedido en ausencia de tratamiento?

- Dado que el efecto causal para una sola unidad u no puede ser observada, intentamos identificar el **efecto causal promedio** para la población entera o para las sub-poblaciones.
- El **efecto de tratamiento promedio** (ATE) de t (relativo a c) sobre U (o cualquier sub-población) está dado por:

$$\begin{aligned}ATE &= E [Y_1(u) - Y_0(u)] \\ &= E [Y_1(u)] - E[Y_0(u)] \\ &= \bar{d} = \bar{Y}_1 - \bar{Y}_0\end{aligned}\tag{1}$$

- La solución estadística reemplaza el efecto causal imposible de observar de t en una unidad específica con la posibilidad de estimar el *efecto causal* promedio de t sobre una población de unidades.
- $E(Y_1)$ y $E(Y_0)$ pueden ser estimados.
- La mayoría de los métodos econométricos intentan construir de datos observacionales estimaciones consistentes de

$$\bar{Y}_1 \text{ y } \bar{Y}_0$$

- Considere el siguiente estimador simple de ATE (“después de tratamiento”):

$$\hat{d} = [\hat{Y}_1 | D = 1] - [\hat{Y}_0 | D = 0] \quad (2)$$

- Note que la ecuación (1) está definida para la población completa, mientras que la ecuación (2) representa un estimador a ser evaluado en una muestra obtenida de esa población.

Asuma que \mathbf{p} es igual a la proporción de la población que sería asignada al grupo de tratamiento.

Se puede descomponer ATE de manera siguiente:

$$\begin{aligned}\bar{d} &= \mathbf{p} \bar{d}_{\{D=1\}} + (1-\mathbf{p}) \bar{d}_{\{D=0\}} \\ &= \mathbf{p} \left[(\bar{Y}_1 - \bar{Y}_0) \mid D = 1 \right] + (1-\mathbf{p}) \left[(\bar{Y}_1 - \bar{Y}_0) \mid D = 0 \right] \\ &= \left[\mathbf{p} [\bar{Y}_1 \mid D = 1] + (1-\mathbf{p}) [\bar{Y}_1 \mid D = 0] \right] + \\ &\quad \left[\mathbf{p} [\bar{Y}_0 \mid D = 1] + (1-\mathbf{p}) [\bar{Y}_0 \mid D = 0] \right] \\ &= \bar{Y}_1 - \bar{Y}_0\end{aligned}$$

Si se supone que

$$[\bar{Y}_1 | D = 1] = [\bar{Y}_1 | D = 0] \quad \text{and} \quad [\bar{Y}_0 | D = 1] = [\bar{Y}_0 | D = 0]$$

entonces

$$\bar{d} = \left[p [\bar{Y}_1 | D = 1] + (1-p) [\bar{Y}_1 | D = 1] \right] + \\ \left[p [\bar{Y}_0 | D = 0] + (1-p) [\bar{Y}_0 | D = 0] \right]$$

$$\bar{d} = [\bar{Y}_1 | D = 1] - [\bar{Y}_0 | D = 0]$$

Lo cual puede ser estimado de manera consistente por:

$$\hat{d} = [\hat{Y}_1 | D = 1] - [\hat{Y}_0 | D = 0]$$

- Así, una condición suficiente para el estimador estándar para estimar consistentemente el ATE verdadero es que:

$$[\bar{Y}_1|D = 1] = [\bar{Y}_1|D = 0] \quad \text{y} \quad [\bar{Y}_0|D = 1] = [\bar{Y}_0|D = 0]$$

- En esta situación, el resultado promedio bajo el tratamiento y el resultado promedio bajo control no difiere entre los grupos de tratamiento y de control.
- A fin de satisfacer estas condiciones, es suficiente que la asignación del tratamiento D no esté correlacionado con las potenciales distribuciones resultantes de Y_1 y Y_0 .
- La forma principal de conseguir esta no-correlación es a través de la asignación aleatoria del tratamiento

- En la mayoría de los casos, simplemente no hay información disponible sobre cómo aquellos individuos en el grupo control habrían reaccionado si hubieran recibido el tratamiento.
- Ésta es la base para comprender los potenciales sesgos del estimador estándar (2).
- Después de un poco de algebra, se puede mostrar que:

$$\hat{\mathbf{d}} = \mathbf{\bar{d}} + \underbrace{\left([\bar{Y}_0 \mid D = 1] - [\bar{Y}_0 \mid D = 0] \right)}_{\text{Diferencia en la línea base}} + (1 - \mathbf{p}) \underbrace{\left(\mathbf{\bar{d}}_{\{D=1\}} - \mathbf{\bar{d}}_{\{D=0\}} \right)}_{\text{Heterogeneidad del tratamiento}}$$

- Esta ecuación especifica las dos fuentes de sesgo que necesitan ser eliminadas de las estimaciones de efectos causales de estudios observacionales.
 1. Sesgo de selección: diferencias en la línea de base.
 2. Heterogeneidad del tratamiento

- La mayoría de los métodos disponibles solamente se enfocan al sesgo de selección, asumiendo que el efecto del tratamiento es constante en la población o redefiniendo los parámetros de interés en la población.

Tratamiento en los tratados

- *ATE* no siempre es el parámetro de interés.
- En una variedad de contextos de política, el efecto de tratamiento promedio *para la persona bajo intervención* es de sumo interés:

$$\begin{aligned}TOT &= E [Y_1(u) - Y_0(u) | D = 1] \\ &= E [Y_1(u) | D = 1] - E [Y_0(u) | D = 1]\end{aligned}$$

Tratamiento en la persona tratada

- El estimador estándar (2) estima consistentemente *TOT* si:

$$[\bar{Y}_0 | D = 1] = [\bar{Y}_0 | D = 0]$$

Referencias

- ❑ Judea Pearl (2000): Causality: Models, Reasoning and Inference, CUP. Chapters 1, 5 and 7.
- ❑ Trygve Haavelmo (1944): “The probability approach in econometrics,” *Econometrica* 12, pp. iii-vi+1-115.
- ❑ Arthur Goldberger (1972): “Structural Equations Methods in the Social Sciences,” *Econometrica* 40, pp. 979-1002.
- ❑ Donald B. Rubin (1974): “Estimating causal effects of treatments in randomized and nonrandomized experiments,” *Journal of Educational Psychology* 66, pp. 688-701.
- ❑ Paul W. Holland (1986): “Statistics and Causal Inference,” *Journal of the American Statistical Association* 81, pp. 945-70, with discussion.