

## EL ANALISIS DE MODELOS CAUSALES. PRINCIPIOS BASICOS DEL METODO SIMON- BLALOCK\*

### RESUMEN

*José A. Cobas, científico social de reconocido prestigio en Estados Unidos y en Latinoamérica, nos presenta la aplicación de un modelo de análisis social, según el método de Simón-Blalock. El modelo matemático que nos ofrece contribuye a determinar las relaciones causales de las diversas variables. No es un sustituto de la teoría, como tampoco ésta lo puede ser del método empírico. Como concluye el autor: "A pesar de su elegancia matemática, los modelos causales reflejan la agudez teórica del investigador; el pensamiento teórico indisciplinado crea modelos pobres; los modelos causales son un instrumento útil, pero no un sustituto de la teoría".*

El propósito de este trabajo es discutir los principios básicos del método Simón-Blalock para análisis de modelos causales. Aunque existen trabajos didácticos sobre esta materia,<sup>1</sup> estos se hallan principalmente en inglés, y, según mi experiencia, trabajos matemáticos escritos en idiomas extranjeros son difíciles de entender. Esta fue la razón principal que me llevó a escribir este artículo.<sup>2</sup>

Se pueden identificar tres enfoques en el análisis de modelos causales en la sociología. El primero, path análisis, es obra del biólogo Sewell Wright, y fue divulgado en la sociología por Otis Dudley Duncan.<sup>3</sup> El segundo, análisis de dependencia, se basa en el trabajo del sociólogo Raymond Boudon.<sup>4</sup> El tercero lo desarrolló el economista Herbert Simon,<sup>5</sup> y logró aceptación en la sociología por medio de los esfuerzos de Hubert Blalock.<sup>6</sup> Nuestra atención se concentrará en este último enfoque.

\* Quiero dar las gracias a Marco A. Cobas por su crítica constructiva a la primera versión de este trabajo.

1. Por ejemplo, Hubert M. Blalock, *Causal Inferences in Nonexperimental Research*. Chapel Hill, Imprenta de la Universidad de Carolina del Norte, 1964.
2. Mi intención también es suplementar con este trabajo mi discusión sobre path análisis, "Introducción a la técnica del path análisis", *Revista Mexicana de Sociología*, Volumen XL, número extraordinario, 1978 en prensa.
3. Otis Dudley Duncan, "Path Analysis: Sociological Examples", *American Journal of Sociology*, Volumen 72, julio 1966, págs. 1-16.
4. Raymond Boudon, "A Method of Linear Causal Analysis", *American Sociological Review*, Volumen 30, Junio, 1965, págs. 365-374.
5. Herbert Simon, "Spurious Correlation: A Causal Interpretation", *Journal of the American Statistical Association*, Volumen 49, 1954, págs. 467-479.
6. Blalock, ob. cit.

## EL SIGNIFICADO DE RELACION CAUSAL

Para nuestros propósitos, podemos definir la relación causal como sigue: X es una causa directa de Y si un cambio en X produce un cambio en Y, siempre y cuando esta relación no se deba a la dependencia conjunta de X y Y de una tercera variable. Dilucidemos estos puntos.

El requerimiento de la covarianza de causa y efecto significa que debe existir una relación entre causa y efecto. Por ejemplo, si sostenemos que el sobrepeso causa la hipertensión arterial, debemos buscar la proporción mayor de hipertensos dentro de los obesos y no dentro de los de peso moderado. En segundo lugar, la causa debe ocurrir antes que el efecto. Si la ceguera ocurre después de la destrucción del nervio óptico, no podemos decir que la ceguera causó la destrucción del nervio óptico. Finalmente, la asociación entre las variables que llamamos causa y efecto no debe ser resultado de la influencia espúrea de un antecedente común. Por ejemplo, aunque la claridad de la escritura de los escolares varía con el tamaño de sus zapatos, no concluimos que el tamaño del zapato causa la claridad de la escritura, ya que sabemos que la edad (el antecedente común) determina tanto el tamaño del zapato como la claridad de la escritura.


Debe señalarse que la causalidad es un concepto que el científico usa para construir sus teorías, y no una propiedad discernible de la naturaleza. Es decir, el investigador nunca observará una variable causando otra variable; solamente observará su covarianza. Por esta razón Blalock asevera que "el enfoque causal pertenece totalmente al nivel teórico. . . las leyes causales no se pueden nunca demostrar empíricamente". Pero añade: "esto no significa que sea inútil pensar en términos causales y desarrollar modelos causales".<sup>7</sup>

## LA ESTRUCTURA DE LOS MODELOS CAUSALES

La figura número 1 representa un modelo causal de tres variables. Como se acostumbra, usamos letras con subíndices numéricos (v.g.,  $X_1$ ,  $X_2$ , etc.) para designar las variables en el modelo. Las variables iniciales en la secuencia causal se denominan "exógenas". Por ejemplo,  $X_1$  es una variable exógena en el modelo que discutimos. A las variables no exógenas se les llama "endógenas".

Las flechas unidireccionales representan efectos causales directos. Por ejemplo, la flecha que conecta las variables  $X_1$  y  $X_2$  representa un efecto causal directo de la primera sobre la segunda.

FIGURA NUMERO 1



Modelos de esta índole incorporan varios supuestos. Primero, las relaciones causales son asimétricas, es decir, si  $X_1$  es una causa de  $X_2$ ,  $X_2$  a su vez no puede ser causa de  $X_1$ . (A los modelos que excluyen la causalidad recíproca se les denomina "recursivos".) Segundo, las variables se han medido en escalas de intervalos. Tercero, las asociaciones entre las variables son lineales y sumables. Cuarto, la varianza no explicada en una variable se atribuye al efecto de una variable residual no medida. Quinto, esta variable residual no se correlaciona con los antecedentes causales de la variable a la que corresponde ni con otras variables residuales en el modelo.<sup>8</sup>

Las relaciones causales representadas en el modelo también pueden expresarse por medio de las siguientes ecuaciones:

$$X_1 = e_1$$

$$X_2 = b_{21}X_1 + e_2$$

$$X_3 = b_{31.2}X_1 + b_{32.1}X_2 + e_3$$

La primera ecuación indica que la varianza de la variable exógena,  $X_1$ , se debe a efectos causales no reconocidos, los cuales representa la variable residual  $e_1$ . La segunda ecuación muestra que la varianza de  $X_2$  se debe a los efectos causales de  $X_1$  y la variable residual  $e_2$ . Finalmente, la última ecuación señala que la varianza de la variable  $X_3$  se debe al efecto causal directo de  $X_1$  (controlando la influencia de  $X_2$ ), al efecto causal directo de  $X_2$  (manteniendo constante el impacto de  $X_3$ ), y a la variable residual  $e_3$ . Debe enfatizarse que el modelo gráfico en la figura número 1 y el sistema de ecuaciones anterior son equivalentes.

Los coeficientes "b" miden la magnitud del efecto causal directo de una variable sobre otra. En los modelos recursivos los coeficientes "b" son análogos o coeficientes de regresión típicos. Recordemos que los coeficientes de regresión típicos indican

Idem, pág. 6

8. Hay circunstancias cuando estos supuestos se modifican o eliminan. Consúltese Otis Dudley Duncan,


Introduction to Structural Equation Models. Nueva York, Academic Press, 1975.

la magnitud del cambio que se produce en la variable dependiente (expresado en unidades estandar) al ocurrir un incremento de una unidad estandar en la variable independiente, controlando las influencias de otras variables independientes. Así pues,  $b_{21}$  indica la magnitud del cambio que ocurre en  $X_2$  (en unidades estandar) al producirse un cambio igual a una unidad estandar en  $X_1$ . De igual manera,  $b_{31.2}$  indica el tamaño del cambio en  $X_3$  al ocurrir un incremento igual a una unidad estandar en  $X_1$ , cuando se mantiene constante la influencia de  $X_2$ . Debe notarse que cuando nos referimos al coeficiente  $b_{21}$  no decimos nada sobre otras variables independientes cuyos efectos se mantienen constantes. Esto se debe a que en el modelo que discutimos,  $X_1$  es la única variable independiente que afecta  $X_2$ .

Existe una relación entre el número máximo de efectos causales directos que un modelo puede acomodar y el número de pares de variables en el mismo modelo. Se puede demostrar,<sup>9</sup> aunque no lo haremos aquí, que en los modelos recursivos el número máximo de efectos causales es igual al número de pares de variables en el modelo. Por ejemplo, el modelo en la figura número 1 contiene el número máximo de efectos causales directos, ya que incluye tres pares de variables y tres efectos causales directos. A aquellos modelos que tienen el número máximo de efectos causales directos se les denomina "identificados" ("Just-identified" en inglés). A aquellos modelos que contienen un número mayor de pares de variables que de efectos causales se les llama "sobreidentificados".

La ausencia de datos efectos causales directos indica que en los modelos sobreidentificados se asume que algunos de los efectos causales directos son iguales a cero. El modelo en la figura número 2 nos sirve para ilustrar este punto. No hay flechas de  $X_1$

a  $X_3$  ni de  $X_2$  a  $X_4$ , lo cual indica que el modelo supone que los efectos causales de  $X_1$  a  $X_3$  y de  $X_2$  a  $X_4$  son iguales a cero. Dicho de otra manera, el modelo incluye las hipótesis de que tanto  $b_{31.2}$  como  $b_{42.13}$  son iguales a cero.



Los supuestos de que ciertos efectos causales directos son iguales a cero forman la base de las pruebas a que se someten los modelos. Como discutiremos seguidamente, estas hipótesis se pueden evaluar basándose en los datos obtenidos empíricamente.

### EVALUACION DE MODELOS CAUSALES

La prueba de la validez de un modelo causal consiste de dos partes: la verificación de las hipótesis implícitas en el modelo y la eliminación de modelos alternos.

#### A) La verificación de las hipótesis.

Como dijimos anteriormente, los modelos sobreidentificados incluyen predicciones al efecto de que cierto efecto o efectos causales son iguales a cero. Estas predicciones o hipótesis se pueden verificar usando los datos empíricos recogidos por el investigador. Pasemos a un ejemplo.

En el modelo A de la figura número 3 el efecto causal de  $X_1$  a  $X_3$  está ausente, lo cual implica la hipótesis de que  $b_{31.2}$  es igual a cero. El investigador ha calculado una matriz de correlaciones de Pearson, la cual aparece debajo del modelo. Usando esta matriz, procedemos a calcular el valor de  $b_{31.2}$  como sigue:

$$b_{31.2} = \frac{r_{31} - r_{12} r_{32}}{\sqrt{1 - r_{32}^2}} = \frac{.05 - (.15)(.30)}{\sqrt{1 - .30^2}} = \frac{.05 - .05}{\sqrt{1 - .09}} = \frac{0}{\sqrt{.91}} = 0$$

Como podemos ver, el valor de  $b_{31.2}$  calculado en base a los datos empíricos es igual a cero. Por lo tanto, concluimos que los datos sostienen la hipótesis predicha por el modelo. En este aspecto, el modelo es adecuado.

Si hubiera otras predicciones implícitas en el modelo, nuestro próximo paso sería examinarlas y comparar los valores obtenidos con los valores predi-

chos de los coeficientes, como hicimos en el caso de  $b_{31.2}$ .

Debemos señalar que si una hipótesis predice que cierto coeficiente de regresión típico es igual a cero, esto equivale a predecir que la correlación parcial correspondiente también es igual a cero. En el caso que discutimos, el supuesto de que  $b_{31.2}$  es igual a cero implica que  $r_{31.2}$  también es igual a cero. Este hecho se puede demostrar examinando la fórmula de  $r_{31.2}$ :

<sup>9</sup> Consulte Blalock, ob. cit., pág. 63 y siguientes.


$$r_{31.2} = \frac{r_{13} - r_{12} r_{32}}{\sqrt{1 - r_{12}^2} \sqrt{1 - r_{32}^2}}$$

Como podemos observar, los numeradores de  $b_{31.2}$  y  $4_{31.2}$  son idénticos, de donde sigue que si  $b_{31.2}$  es igual a cero,  $r_{31.2}$  también lo es. (Recordemos que la división por cero no es permitida; por lo tanto, el denominador de una fracción no puede ser

igual a cero. Así pues, si  $b_{31.2}$  es igual a cero, es porque el numerador es igual a cero. Y si el numerador de  $b_{31.2}$  es igual a cero,  $r_{31.2}$  también es igual a cero.)

Debido a la relación que existe entre los coeficientes de regresión típicos y las correlaciones parciales, las predicciones de un modelo pueden formularse en términos de ambos tipos de coeficiente. Empero, cuando estas predicciones se formulan en la literatura, invariablemente usan coeficientes de correlación. Esto se debe más a costumbre que a necesidad estadística, ya que ambos tipos de coeficientes se prestan para tales hipótesis.

FIGURA NUMERO 3



## MATRIZ CORRELACIONAL

|                | X <sub>1</sub> | X <sub>2</sub> | X <sub>3</sub> | X <sub>4</sub> |
|----------------|----------------|----------------|----------------|----------------|
| X <sub>1</sub> | 1.00           | .15            | .05            | .21            |
| X <sub>2</sub> |                | 1.00           | .30            | .31            |
| X <sub>3</sub> |                |                | 1.00           | .31            |
| X <sub>4</sub> |                |                |                | 1.00           |


Es necesario apuntar que las hipótesis de un modelo se refieren a poblaciones o universos, y no a muestras. Es decir, la predicción de que un coeficiente es igual a cero se relaciona con el valor del coeficiente en el universo. Por esta razón, cuando utilizamos datos muestrales (lo cual es perfectamente adecuado), no esperamos necesariamente que la hipótesis se cumpla con exactitud, debido a la posibilidad de errores de muestreo. Esta posibilidad tiene como resultado el hecho de que si surge una diferencia entre el valor predicho y el valor observado de un coeficiente, hay que decidir si la diferencia se debe a que la hipótesis no se cumplió o a errores de muestreo. ¿Cómo procede el investigador? Una posibilidad es escoger arbitrariamente una cantidad, como .05, la cual establece un límite que la diferencia entre el valor observado y el valor predicho de un coeficiente no debe exceder. Si la diferencia sobre-

pasa este límite, el modelo se considera defectuoso en ese aspecto; si no, la diferencia se atribuye a errores de muestreo. Otra posibilidad es optar por una de las pruebas de significancia que existen para investigar la hipótesis nula de que la diferencia en el universo es igual a cero.

B) El examen de modelos alternos.

La segunda parte de la evaluación de un modelo causal consiste en el examen de modelos alternos plausibles, si es que existen. Ya que la teoría social no es precisa, los modelos causales raramente presentan estructuras causales unívocas. Por esta razón el modelo con el que el investigador comienza es una de varias alternativas atendibles. Veamos un ejemplo concreto.

Ya hemos discutido el modelo A en la figura número 3. Supongamos que la teoría no precisa si debe existir un efecto causal directo de X<sub>2</sub> a X<sub>4</sub>.



Debemos observar que el modelo A incorpora tal efecto, mientras que el modelo B lo omite. ¿Cómo escoger entre estas alternativas?

El modelo B contiene dos predicciones:  $r_{13.2} = 0$  y  $r_{42.13} = 0$ . Procedemos primero a calcular el valor de  $r_{13.2}$ , como sigue:

$$r_{13.2} = \frac{r_{13} - r_{12} r_{32}}{\sqrt{1 - r_{12}^2} \sqrt{1 - r_{32}^2}} = \frac{0.5 - (.15)(.30)}{\sqrt{1 - .15^2} \sqrt{1 - .30^2}} = \frac{0.5 - .05}{\sqrt{.98} \sqrt{.91}} = \frac{0.45}{\sqrt{.89}} = 0$$

Para calcular el valor de  $r_{24.13}$  usaremos la siguiente fórmula:

$$r_{24.13} = \frac{r_{24.1} - r_{23.1} r_{43.1}}{\sqrt{1 - r_{23.1}^2} \sqrt{1 - r_{43.1}^2}}$$

Como podemos observar, necesitamos calcular tres correlaciones parciales, a saber,  $r_{24.1}$ ,  $r_{23.1}$  y  $r_{43.1}$ . Estas correlaciones se calculan con los datos de la matriz correlacional, y omitimos aquí descri-

bir su cómputo para ahorrar espacio. Baste decir que el valor de  $r_{24.1}$  es igual a .29, el de  $r_{23.1}$  es igual a .29, y el de  $r_{43.1}$  es igual a .32. Utilizando estas cifras, tenemos que:

$$r_{24.13} = \frac{.29 - (.29)(.32)}{\sqrt{1 - .29^2} \sqrt{1 - .32^2}} = \frac{.29 - .09}{\sqrt{1 - .08} \sqrt{1 - .10}} = \frac{.20}{\sqrt{.92} \sqrt{.90}} = \frac{.20}{\sqrt{.91}} = .22$$

Para resumir: el valor predicho y el valor observado de  $r_{13.2}$  son iguales a 0; el valor predicho de  $r_{24.13}$  es igual a cero, pero su valor observado es igual a .22. Tal diferencia es excesiva, por lo que concluimos que los datos no sostienen la segunda hipótesis. En vista a estos resultados, el investigador decidirá que el modelo A es más adecuado que el modelo B.





El examen de modelos alternos debe limitarse a aquéllos que parecen ser atendibles teóricamente. Si el investigador fuera a examinar modelos al azar, tal ejercicio sería francamente inútil.

Antes de cerrar esta sección, debe apuntarse que la falta de precisión en la teoría social puede dar lugar a situaciones en las que nos es imposible

decidir entre dos modelos alternos solamente en base a los datos empíricos. Por ejemplo, considere los modelos  $X \rightarrow Y \rightarrow Z$  y  $Z \rightarrow Y \rightarrow X$ . Ambos predicen que  $r_{xz,y} = 0$ . Si los datos coinciden con la predicción tendremos que utilizar criterios no estadísticos (como la teoría) para seleccionar entre los modelos.

### MAS EJEMPLOS

Seguidamente presentamos varios ejemplos de modelos causales con el objeto de que el lector los examine y formule las predicciones implícitas en cada uno. Las respuestas aparecen al final de esta sección.



Respuestas: a)  $r_{14.23} = 0$ ;  $r_{13.2} = 0$ . b)  $r_{32.1} = r_{14.32} = 0$ . c)  $r_{43.12} = 0$ .

d) Ya que el modelo no es sobreidentificado, no contiene ninguna predicción.

### CONCLUSION

El propósito de este trabajo ha sido presentar los rudimentos del análisis de modelos causales usando el método Simon-Blalock. Aquellos lectores que quieran profundizar en esta materia pueden comenzar con el artículo de Blalock que se titula "Four-Variable Causal Models and Partial Correlations".<sup>10</sup>

Antes de concluir, debe apuntarse que a veces el análisis de modelos causales nos puede dar un sentido falso de seguridad. A pesar de su elegancia matemática, los modelos causales reflejan la agudeza teórica del investigador; el pensamiento teórico indisciplinado crea modelos causales pobres. Los modelos causales son un instrumento útil, pero no un sustituto de la teoría.

10. Hubert Blalock, "Four-Variable Causal Models and Partial Correlations", *American Journal of Sociology*. Volumen 68, 1962, págs. 182-194.