

# **Endogeneidad y heterogeneidad no observada**

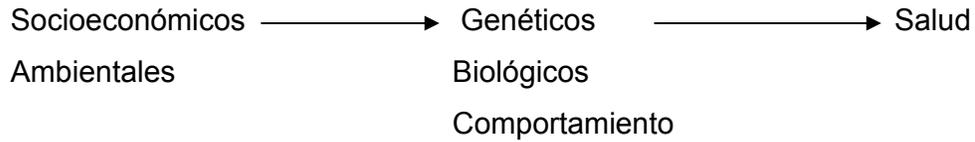
Preparado por Guido Pinto Aguirre (actualizado a Abril 2010)

## **Menú de hoy:**

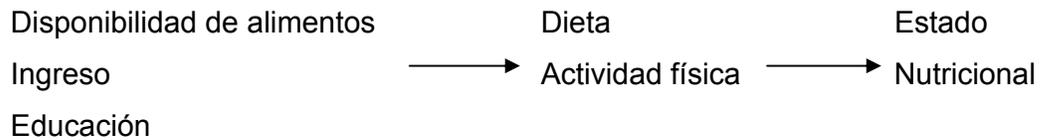
- 1. Referencia**
- 2. Modelo de regresión clásico y endogeneidad**
- 3. Heterogeneidad no observada**
- 4. Ejemplo en salud**
- 5. Ecuaciones simultaneas**

6.

## 1. Referencia



Por **ejemplo**:



Cuando los modelos se vuelven complicados, existe la posibilidad que una variable explicativa en una ecuación sea dependiente en otra ecuación.

Estado Nutricional = f (dieta, actividad física)

Dieta = f (características individuales)

## 2. Modelo de regresión clásico y Endogeneidad

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_k X_k + \varepsilon$$

La heterogeneidad (variabilidad) entre observaciones individuales o sujetos es una condición importante para el funcionamiento apropiado de los modelos estadísticos

La variación de una característica individual dada (variable dependiente) en una población o muestra esta explicada por la heterogeneidad existente un conjunto de características observadas (variables explicativas)

Si los modelos fueran perfectos, es decir, si todas las variables posibles podrían ser incluidas en el modelo y además si podrían ser medidas sin error; entonces, las variables independientes incluidas podrían explicar toda la variación en la variable dependiente (el coeficiente de correlación múltiple sería 1)

En este caso todas las observaciones estarían sobre la línea de regresión o el hiperplano de regresión

Sin embargo, en la práctica ningún modelo es perfecto.

Variaciones puramente aleatorias (ruido blanco) en el lado de las variables explicativas requiere la incorporación de un componente denominado “término error” a fin de capturar aquella parte de la variación en la variable dependiente que explicada por la heterogeneidad de las variables explicativas

Sea el modelo:

$$Y = \beta_0 + \beta_1 X + \beta_2 Z + \varepsilon$$

Supuestos del modelo sobre el modelo y  $\varepsilon$ 's son los siguientes:

### **Lineal en los parámetros**

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

Donde  $\varepsilon$  es no observable

### **Muestreo aleatorio**

Se utiliza una muestra aleatoria de la población bajo estudio.

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$$

Donde  $\{(X_i, Y_i) \mid i=1, \dots, n\}$  es una muestra aleatoria de tamaño  $n$

### **Exogeneidad estricta**

$$E(\varepsilon_i \mid x_i) = 0, \text{ para todo } i=1, \dots, n$$

Entonces la variable  $x$  se denomina exógena; pero si  $\varepsilon$  y  $x$  están correlacionadas, entonces  $x$  se denomina variable endógena.

De manera equivalente podemos decir que  $Cov(\varepsilon_i | x_i) = 0$

### **Heterogeneidad de la variable independiente**

En la muestra, la variable independiente  $X$  no es igual a una constante. Esto requiere alguna variación en  $X$  en la población, es decir,

$$\sum (x_i - x^*) > 0$$

Donde  $x^*$  es el promedio de  $x$

### **Homoscedasticidad**

$Var(\varepsilon_i | X_i) = \sigma$ , para todo  $i=1, \dots, n$

### **Multicolinealidad**

En la muestra (y en consecuencia en la población) no existe una relación lineal perfecta entre las variables explicativas

### **Correlación serial**

Condicionales en  $X$ , los errores de dos individuos diferentes o dos periodos diferentes no están correlacionados entre sí

$Corr(\varepsilon_i, \varepsilon_j | x_i) = 0$ , para todo  $i \neq j$

### **Normalidad**

El error poblacional  $\varepsilon$  es independiente de la variable explicativa  $x$  y está distribuido normalmente

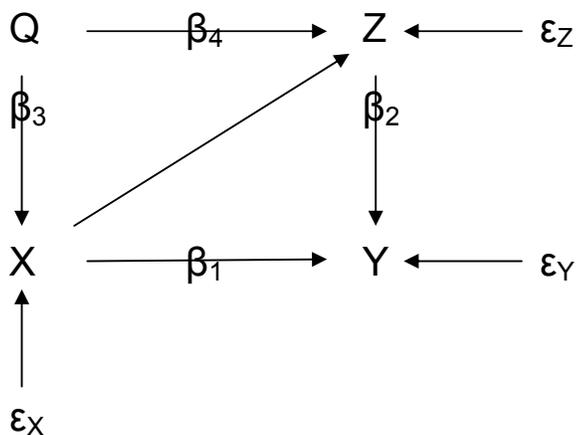
$$\varepsilon \sim N(0, \sigma^2)$$

Si estos supuestos se cumplen, entonces se dice que el modelo es apropiado para los datos disponibles

Una de los supuestos más importantes es el que asume independencia entre  $\varepsilon$  y las variables explicativas

Pero muchos modelos son más complicados que el presentado arriba. Por ejemplo, podemos considerar el caso en que X & Z están conjuntamente determinadas por otra variable, denominada Q

Esta situación se puede expresar como:



La variable Y está determinada por el efecto combinado de X & Z, las cuales están a la vez determinadas por Q

Es decir, Q no es parte explícita del modelo:

$$Y = \beta_1 X + \beta_2 Z + \varepsilon_Y$$

En consecuencia, la relación implícita puede ser especificada mediante tres ecuaciones:

$$Y = \beta_1 X + \beta_2 Z + \varepsilon_Y$$

$$X = \beta_3 Q + \varepsilon_X$$

$$Z = \beta_4 Q + \varepsilon_Z$$

La variable Z se denomina variable de confusión en la relación X –Y, es decir, parece un factor explicativo de la variable Y correlacionado con la variable X pero que **no es** parte la relación causal entre X & Y

En consecuencia, Z tiene que ser controlada de alguna forma, puesto que ignorar su efecto (al dejarla fuera de la ecuación) produciría un estimado sesgado del efecto que tiene X sobre Y

De manera similar, ignorar Q, el cual es determinante de X & Z, conduce a una situación similar a la anterior (confusora)

Se pueden identificar dos tipos de variables: Q es una variable exógena (sus determinantes no son parte del modelo), mientras que X & Z son variables endógenas (están determinadas por otras variables en el modelo de 3 ecuaciones)

En la primera ecuación frecuentemente asumimos que el termino error  $\varepsilon$  es puramente aleatorio, es decir, no está correlacionado con X & Z



### 3. Heterogeneidad no observada

Supongamos ahora que la variable dependiente  $Y$  está afectada no sólo por  $X$ ,  $Z$  y variaciones puramente aleatorias sino también por ciertos factores no aleatorios específicos a cada individuo, los cuales no son observables o medibles, tales como factores genéticos de predisposición

En este caso el modelo puede escribirse como:

$$Y = \beta_1 X + \beta_2 Z + \mu H + v_Y$$

Donde  $v_Y$  es un residual verdaderamente aleatorio y  $H$  contiene las características no observadas para cada individuo y  $\mu$  es el parámetro que explica la relación entre  $Y$  y  $H$ . Además

$$\varepsilon_Y = \mu H + v_Y$$

La variable  $H$  representa las diferencias **no aleatorias** que existen entre observaciones o individuos pero que no pueden medirse directamente

El efecto de no poder incluir explícitamente  $H$  en el modelo depende del supuesto que se haga sobre la relación

que puede existir entre H y las otras variables explicativas del modelo

Si se asume que

$$\text{Cov}(H, X)=0, \text{Cov}(H, Z)=0$$

Entonces dejar fuera de la ecuación el término  $\mu H$  conducirá a un modelo subespecificado con un residual más grande.

Sin embargo, no tendrá ningún efecto sobre el tamaño de los coeficientes sino que producirá errores estándar más grandes de lo que deberían ser

Pero si

$$\text{Cov}(H, X) \neq 0, \text{Cov}(H, Z) \neq 0$$

Entonces, la heterogeneidad no observada estará correlacionada con las variables explicativas, actuando como variable confusora

Consideremos el siguiente sistema de ecuaciones:

$$Y = \alpha_1 X + \alpha_2 Z + \mu_1 H_Y + \varepsilon_Y$$

$$Z = \beta_1 V + \beta_2 W + \mu_2 H_Z + \varepsilon_Z$$

La variable endógena Z es en parte una función de características no observables  $H_Z$ , que se encuentra correlacionada con  $H_Y$ , es decir,  $Cov(H_Z, H_Y) \neq 0$

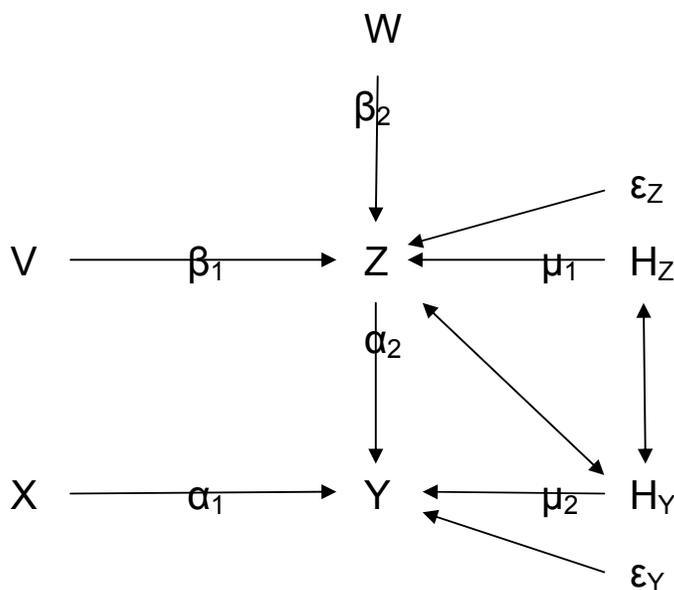
En consecuencia, Z esta correlacionada con  $H_Y$ .  
Entonces, la variable  $H_Y$  (aunque no observable) actúa a través del error

$$\varepsilon'_Y = \mu_1 H_Y + \varepsilon_Y$$

y es un factor de riesgo para la variable Y, al mismo tiempo que esta correlacionada con otra variable explicativa Z.

Entonces,  $H_Y$  opera como confusora de la relación Z – Y.

La representación gráfica es la siguiente manera:



En este modelo Y & Z son variable endógenas, mientras que X, V & W son exógenas

Cada ecuación que describe el comportamiento de  $Y$  &  $Z$  tiene asociadas un error puramente aleatorio ( $\varepsilon$ ) y heterogeneidad no observada ( $H$ )

Se observa que en lugar de controlar directamente por la heterogeneidad no observada, existe una manera de prevenir que “actúe” como confusora

Sabemos que  $H_Y$  es una confusora de la relación  $Z - Y$  debido a que la correlación con  $Z$  no es cero pero que al mismo tiempo es un factor de riesgo para  $Y$

En consecuencia, **si** la asociación entre  $H_Y$  y  $Z$  puede ser eliminada, entonces dejara de ser confusora

En econometría existen métodos para remover de estos modelos variables confusoras: encontrar una variable denominada instrumento

Una **variable instrumental** debe estar altamente, aunque no completamente, correlacionada con la variable endógena pero no correlacionada con el término error

El instrumento es entonces utilizado para sustituir la variable endógena original

En el sistema anterior, podemos que ambas  $V$  y  $W$  son posibles candidatas para un instrumento de  $Z$

Cuando se tienen datos longitudinales, una posible solución es utiliza el rezago de la variable endógena como instrumento (variable endógena del periodo anterior)

En econometría uno de los mejores instrumentos es el valor predicho de la variable endógena como función de todas las variables exógenas en el sistema.

Esto se conoce como estimación de la **forma reducida**. Este estimado es entonces utilizado como el instrumento para la variable endógena en la ecuación original

En el caso anterior, se debe sustituir el valor predicho de  $Z$  (que ahora no estará correlacionado con  $H_Y$ ) en lugar del valor medido de  $Z$  (que esta correlacionado con  $H_Y$ ).

Este método se denomina Mínimos Cuadrados dos Etapas

#### 4. Ejemplo

El efecto de la lactancia en el regreso de la fecundabilidad puede ser representado como:

$$M_{ti} = \alpha_1 + \alpha_2 BF_{ti} + \alpha_3 X_{ti} + \mu_{(M)i} + \varepsilon_{(M)ti}$$

M: probabilidad de retorno de la fecundabilidad

BF: medidas de lactancia (frecuencia, intensidad, etc.)

X: otras variables explicativas como paridad, peso, energía, ingesta de alimentos, gasto de energía, actividad sexual, etc.

$\mu_{(M)i}$ : término error específico a cada individuo (i) que no cambia con el tiempo (heterogeneidad no observada)

$\varepsilon_{(M)ti}$ : error puramente aleatorio

En esta ecuación  $\mu$  puede pensarse como una variable omitida y una fuente potencia de confusión

La relación de comportamiento de la lactancia puede escribirse como:

$$BF_{ti} = \beta_1 + \beta_2 M_{ti} + \beta_3 Y_{ti} + \mu_{(BF)i} + \varepsilon_{(BF)ti}$$

Y: incluye factores como edad de la madre, paridad, anticoncepción

En la primera ecuación, BF y  $\mu$  pueden estar correlacionadas, que convierte a BF en una variable endógena.

Esta es una fuente de sesgo y también puede existir una situación de confusión

### **Corrección por Endogeneidad**

Una técnica estándar para remover la correlación que existe [ $Cov(x, \varepsilon) \neq 0$ ] es el uso de una variable instrumental.

Cada variable endógena es reemplazada por una variable sustituta, una variable instrumental (VI)

Esta VI debe estar correlacionado con la variable endógena pero no con el termino error

Para crear una VI se debe desarrollar una ecuación de “forma reducida”, la cual predice los valores de la variable endógena a partir de un conjunto de variables estrictamente exógenas

## 5. Ecuaciones simultáneas

### Naturaleza

Los modelos uniecuacionales desafortunadamente ignoran la interdependencia que existe entre las variables en el mundo real. Los modelos más importantes en las ciencias sociales son de naturaleza simultánea

El ejemplo más clásico de simultaneidad en economía es la oferta y demanda de bienes y servicios. Estudiar la demanda de carne sin analizar la oferta de carne es tomar riesgos de omitir importantes relaciones e incurrir en errores significativos

La preocupación de la econometría por las ecuaciones simultáneas aparece en el momento de su estimación utilizando MCO. Si este es el caso, se producen una serie de dificultades que no se encuentran con modelos uniecuacionales.

En las ecuaciones simultáneas principalmente no se cumple el supuesto clásico sobre la no correlación del término error con todas las variables explicativas. Es decir,

$$\text{cov}(\varepsilon_i, X_i) = 0$$

Debido a este incumplimiento, los estimados MCO de los coeficientes son **sesgados** en los modelos simultáneos. El procedimiento de estimación denominado Mínimos Cuadrados en Dos Etapas (MC2E) se utiliza en tales modelos en lugar de MCO

## **Ecuaciones estructurales**

¿Qué viene primero, la oferta o la demanda? Esta pregunta es difícil de responder en forma satisfactoria porque oferta y demanda están determinadas conjuntamente; existe una relación causal de ida y vuelta entre las variables.

El mundo económico está lleno de este tipo de efectos de retroalimentación y causalidad en dos direcciones que requieren la aplicación de ecuaciones simultaneas. Además de la oferta y demanda y modelos de macroeconómicos simples, se puede mencionar la causalidad bidireccional que existe entre el tamaño de la población y oferta de alimentos, la determinación conjunta de los salarios y precios

Una ecuación simple econométrica típica se escribe como:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \varepsilon_t$$

En cambio, un sistema simultáneo es aquel en el cual Y claramente tiene un efecto sobre al menos una de las Xs en adición al efecto que las Xs tienen sobre Y.

Estas relaciones se modelan al distinguir entre aquellas variables que se determinan simultáneamente tales como las Ys, que se denominan **variables endógenas**, y aquellas que no se determinan simultáneamente como las Xs, que se denominan **variables exógenas**.

En el siguiente sistema:

$$Y_{1t} = \alpha_0 + \alpha_1 Y_{2t} + \alpha_2 X_{1t} + \alpha_3 X_{2t} + \varepsilon_{1t}$$

$$Y_{2t} = \beta_0 + \beta_1 Y_{1t} + \beta_2 X_{3t} + \beta_3 X_{2t} + \varepsilon_{2t}$$

La primera ecuación caracteriza el comportamiento de los consumidores y la segunda ecuación muestra el comportamiento de los oferentes de un producto

Estas relaciones de comportamiento se denominan **ecuaciones estructurales**, caracterizan la teoría económica que existe detrás de cada variable endógena al expresarlas en términos de variables endógenas y exógenas

Los econométricos deben ver las ecuaciones estructurales como un sistema a fin de percibir las retroalimentaciones involucradas. Por ejemplo, el hecho que las Ys están determinadas conjuntamente significa que un

cambio en  $Y_1$  causará un cambio en  $Y_2$ , lo que a su vez ocasionara que  $Y_1$  cambie nuevamente

Se puede comparar este mecanismo de retroalimentación con un cambio en  $X_1$ , el cual no causará retroalimentación para que  $X_1$  cambie nuevamente

Los parámetros  $\alpha$  y  $\beta$  en las ecuaciones estructurales se denominan **coeficientes estructurales**; las hipótesis deben realizarse sobre sus signos de la misma manera que se hacen sobre los coeficientes de regresión de los modelos uniecuacionales

Es importante aclarar que una variable es endógena porque está determinada conjuntamente y no sólo porque aparece en ambas ecuaciones. Por ejemplo,  $X_2$  está en ambas ecuaciones pero es de naturaleza exógena porque no está determinada simultáneamente en el mercado de algún producto

¿Cómo se decide si una variable en particular debería ser endógena o exógena? Algunas variables son casi siempre exógenas (como el tiempo) pero muchas otras pueden ser consideradas endógenas o exógenas, dependiendo del número y características de las otras ecuaciones en el sistema

En consecuencia, la distinción entre variables endógenas y exógenas depende de cómo el investigador define el enfoque de la investigación

Muchas veces, variables endógenas rezagadas aparecen en sistemas simultáneos, especialmente cuando las ecuaciones involucradas son ecuaciones de rezagos distribuidos

A fin de evitar la confusión que puede existir cuando se tienen variables rezagadas, se definen las **variables predeterminadas** para incluir todas las variables exógenas y endógenas rezagadas

Predeterminadas significa que las variables exógenas y endógenas rezagadas son determinadas fuera del sistema de ecuaciones especificadas o en un momento anterior al periodo actual.

Variables endógenas que no están rezagadas no son predeterminadas porque son conjuntamente determinadas por el sistema en el periodo de tiempo actual

En consecuencia, los econométricos tienden a hablar en términos de variables endógenas y predeterminadas cuando se discuten sistemas de ecuaciones simultáneas

La especificación de un modelo simple de oferta y demanda puede realizarse en los siguientes términos:

$$Q_{Dt} = \alpha_0 + \alpha_1 P_t + \alpha_2 X_{1t} + \alpha_3 X_{2t} + \varepsilon_{Dt}$$

$$Q_{St} = \beta_0 + \beta_1 P_t + \beta_2 X_{3t} + \varepsilon_{St}$$

$$Q_{Dt} = Q_{St} \text{ (condición de equilibrio)}$$

Donde:

$Q_{Dt}$ : cantidad de la bebida gaseosa demanda en el período t

$Q_{St}$ : cantidad de la bebida gaseosa ofertada en el período de tiempo t

$P_t$ : precio de la bebida gaseosa en el periodo de tiempo t

$X_{1t}$ : dólares en publicidad para la gaseosa en el periodo de tiempo t

$X_{2t}$ : variable exógena del lado de la demanda (ingreso, precio de otras bebidas gaseosas, etc.)

$X_{3t}$ : variable exógena del lado de la oferta (precio de sabores artificiales, u otros factores de producción)

$\varepsilon_t$ : término error clásico, cada ecuación tiene su propio error

En este caso, el precio y la cantidad están determinados simultáneamente pero una de las variables endógenas no se encuentra en el lado izquierdo de ninguna de las ecuaciones

Por lo tanto, es incorrecto asumir automáticamente que las variables endógenas son sólo aquellas que aparecen en el lado izquierdo de al menos una de las ecuaciones

En este caso particular, podríamos haber escrito la segunda ecuación con el precio en el lado izquierdo y la cantidad ofertada en el lado derecho, como se hizo en las ecuaciones de la carne de res. Mientras que los coeficientes estimados serían diferentes, las relaciones subyacentes no serían diferentes

Debe haber tantas ecuaciones como variables endógenas. En el ejemplo anterior, las variables endógenas son  $Q_D$ ,  $Q_S$  y  $P$

¿Cuáles serían los signos esperados de los coeficientes del precio en las ecuaciones de demanda y oferta? Se esperaría que sea negativo en la ecuación de demanda y positivo en la de oferta; es decir,  $\alpha_1 < 0$  y  $\beta_1 > 0$ . En efecto, la teoría económica dice que cuanto más alto es el precio mayor será la cantidad demandada pero mayor será la cantidad ofertada.

¿Qué pasaría si por accidente colocamos una variable predeterminada del lado de la oferta en la ecuación de la demanda? Se producirían dificultades en identificar cuál ecuación es de demanda y cuál es de oferta, y los signos

esperados de los coeficientes de la variable endógena P serían ambiguos

Por lo tanto, se debe tener cuidado cuando se especifican las ecuaciones estructurales de un sistema

### **Incumplimiento del supuesto clásico $cov(X_i, \varepsilon_i) = 0$**

Uno de los supuestos clásicos requiere que el término error y cada una de las variables explicativas (independientes) en el modelo no deben estar correlacionados

Si existe tal correlación, entonces el método de estimación de MCO es probable que atribuya a una variable explicativa en particular variaciones en la variable dependiente que en realidad están siendo causadas por variaciones en el término error El resultado serán *estimados sesgados*

Para visualizar cómo las ecuaciones simultáneas incumplen el supuesto de independencia entre el término error y las variables explicativas, se marcan las variables involucradas en el sistema presentado al inicio de la exposición. ¿Qué sucede cuando uno de los términos de error aumenta, manteniendo constante todo los demás en la ecuación?

$$Y_{1t} = \alpha_0 + \alpha_1 Y_{2t} + \alpha_2 X_{1t} + \alpha_3 X_{2t} + \varepsilon_{1t}$$

$$Y_{2t} = \beta_0 + \beta_1 Y_{1t} + \beta_2 X_{3t} + \beta_3 X_{2t} + \varepsilon_{2t}$$

Si  $\varepsilon_1$  aumenta en un período de tiempo, entonces  $Y_1$  también aumentará (primera ecuación). En consecuencia, si  $Y_1$  aumenta,  $Y_2$  también aumentará (segunda ecuación), asumiendo que  $\beta_1 > 0$ . Pero si  $Y_2$  aumenta en la segunda ecuación, también aumentará en la primera ecuación donde es una variable explicativa

En consecuencia, un aumento en el término error de una ecuación ocasiona un incremento en una variable explicativa en la misma ecuación: si  $\varepsilon_1$  aumenta,  $Y_1$  aumenta y entonces  $Y_2$  aumenta, incumpléndose el supuesto de independencia entre el término error y las variables explicativas

Por lo tanto, todo lo que se requiere para el incumplimiento del supuesto de independencia mencionado es que las variables endógenas estén determinadas conjuntamente en un sistema de ecuaciones simultáneas

## **Ecuaciones de forma reducida**

Una forma alternativa de expresar un sistema de ecuaciones simultáneas es a través del uso de las **ecuaciones de forma reducida**, las cuales expresan una variable endógena particular sólo en términos del error y todas las variables predeterminadas (exógenas y endógenas rezagadas) en el sistema simultáneo

Las ecuaciones en forma reducida de las ecuaciones estructurales anteriores serian las siguientes:

$$Y_{1t} = \pi_0 + \pi_1 X_{1t} + \pi_2 X_{2t} + \pi_3 X_{3t} + v_{1t}$$

$$Y_{2t} = \pi_4 + \pi_5 X_{1t} + \pi_6 X_{2t} + \pi_7 X_{3t} + v_{2t}$$

Donde las  $v_s$  son los términos de error estocásticos y las  $\pi_s$  son los **coeficientes de la forma reducida** debido a que son los coeficientes de las variables predeterminadas en las ecuaciones en forma reducida

Ahora cada ecuación contiene sólo una variable endógena, como variable dependiente, y el mismo número de de variables predeterminadas

Los coeficientes de la forma reducida ( $\pi_s$ ) son conocidos como **multiplicadores de impacto** porque miden el impacto en la variable endógena del incremento en una unidad en el valor de la variable predeterminada, después de controlar por los efectos de retroalimentación en todo el sistema simultáneo

En el ejemplo de la oferta y demanda de las bebidas gaseosas la especificación de las ecuaciones de forma reducida para el modelo se traduce en sólo dos ecuaciones

puesto que la condición de equilibrio (tercera ecuación) obliga a que la cantidad demandada ( $Q_D$ ) sea igual a la cantidad ofertada ( $Q_S$ ):

$$P_t = \pi_0 + \pi_1 X_{1t} + \pi_2 X_{2t} + \pi_3 X_{3t} + v_{1t}$$

$$Q_t = \pi_4 + \pi_5 X_{1t} + \pi_6 X_{2t} + \pi_7 X_{3t} + v_{2t}$$

Aunque el precio ( $P$ ) nunca aparece en el lado izquierdo de ninguna ecuación estructural, es una variable endógena y debe ser tratada como tal

Existen al menos 4 razones para utilizar las ecuaciones de forma reducida:

**Primero**, puesto que las ecuaciones de forma reducida no tienen simultaneidad inherente, ahora cumplen el supuesto de independencia entre el término error y las variables independientes. En consecuencia, pueden ser estimadas mediante MCO sin encontrar los problemas discutidos anteriormente.

**Segundo**, Los coeficientes de la forma reducida estimados de esta manera pueden ser utilizados para obtener los coeficientes estructurales estimados. Es decir, las ecuaciones estimadas de forma reducida se pueden utilizar para obtener los coeficientes estimados  $\alpha_s$  y  $\beta_s$  de las ecuaciones estructurales.

Este método de calcular los coeficientes estimados estructurales a partir de los coeficientes en forma reducida se denomina Mínimos Cuadrados Indirectos (MCI). Pero MCI es útil en situaciones muy limitadas.

**Tercero**, la interpretación de los coeficientes en forma reducida como multiplicadores de impacto significa que tienen significado económico y una aplicación útil. Por ejemplo, si se quiere comparar un aumento en los gastos de gobierno con una reducción de impuestos en términos del impacto por dólar en el primer año, estimados de los multiplicadores ( $\pi_s$ ) permitirían tal comparación

**Cuarto**, las ecuaciones de forma reducida tienen un rol crucial en la técnica de estimación más frecuentemente utilizada para ecuaciones simultáneas. Esta técnica se denomina Mínimos Cuadrados en dos Etapas (MC2E)

### **Obtención de los coeficientes de la forma reducida**

Sean las ecuaciones incluidas en el modelo de las bebidas gaseosas:

$$Q_{Dt} = \alpha_0 + \alpha_1 P_t + \alpha_2 X_{1t} + \alpha_3 X_{2t} + \varepsilon_{Dt}$$

$$Q_{St} = \beta_0 + \beta_1 P_t + \beta_2 X_{3t} + \varepsilon_{St}$$

$$Q_{Dt} = Q_{St} \text{ (condición de equilibrio)}$$

Se puede utilizar la condición de equilibrio para igualar las ecuaciones anteriores y despejar el precio:

$$\alpha_0 + \alpha_1 P_t + \alpha_2 X_{1t} + \alpha_3 X_{2t} + \varepsilon_{Dt} = \beta_0 + \beta_1 P_t + \beta_2 X_{3t} + \varepsilon_{St}$$

$$\alpha_1 P_t - \beta_1 P_t + \alpha_2 X_{1t} + \alpha_3 X_{2t} + \varepsilon_{Dt} = \alpha_0 + \beta_0 + \beta_2 X_{3t} + \varepsilon_{St}$$

$$(\alpha_1 - \beta_1) P_t = -\alpha_2 X_{1t} - \alpha_3 X_{2t} - \varepsilon_{Dt} + \alpha_0 + \beta_0 + \beta_2 X_{3t} + \varepsilon_{St}$$

$$(\alpha_1 - \beta_1) P_t = (\alpha_0 + \beta_0) - \alpha_2 X_{1t} - \alpha_3 X_{2t} + \beta_2 X_{3t} + (\varepsilon_{St} - \varepsilon_{Dt})$$

$$P_t = (\alpha_0 + \beta_0) / (\alpha_1 - \beta_1) - \alpha_2 / (\alpha_1 - \beta_1) X_{1t} - \alpha_3 / (\alpha_1 - \beta_1) X_{2t} + \beta_2 / (\alpha_1 - \beta_1) X_{3t} + (\varepsilon_{St} - \varepsilon_{Dt}) / (\alpha_1 - \beta_1)$$

La anterior expresión puede escribir:

$$P_t = \pi_0 + \pi_1 X_{1t} + \pi_2 X_{2t} + \pi_3 X_{3t} + v_{1t}$$

Reemplazando  $P_t$  en la ecuación de oferta o demanda se tiene que:

$$Q_t = \beta_0 + \beta_1 (\pi_0 + \pi_1 X_{1t} + \pi_2 X_{2t} + \pi_3 X_{3t} + v_{1t}) + \beta_2 X_{3t} + \varepsilon_{St}$$

$$Q_t = \beta_0 + \beta_1 \pi_0 + \beta_1 \pi_1 X_{1t} + \beta_1 \pi_2 X_{2t} + \beta_1 \pi_3 X_{3t} + \beta_1 v_{1t} + \beta_2 X_{3t} + \varepsilon_{St}$$

$$Q_t = \beta_0 + \beta_1 \pi_0 + \beta_1 \pi_1 X_{1t} + \beta_1 \pi_2 X_{2t} + \beta_1 \pi_3 X_{3t} + \beta_1 v_{1t} + \beta_2 X_{3t} + \varepsilon_{St}$$

$$Q_t = (\beta_0 + \beta_1 \pi_0) + \beta_1 \pi_1 X_{1t} + \beta_1 \pi_2 X_{2t} + (\beta_1 \pi_3 + \beta_2) X_{3t} + (\beta_1 v_{1t} + \varepsilon_{St})$$

$$Q_t = \pi_4 + \pi_5 X_{1t} + \pi_6 X_{2t} + \pi_7 X_{3t} + v_{2t}$$

En consecuencia, las ecuaciones de forma reducida son:

$$P_t = \pi_0 + \pi_1 X_{1t} + \pi_2 X_{2t} + \pi_3 X_{3t} + v_{1t}$$

$$Q_t = \pi_4 + \pi_5 X_{1t} + \pi_6 X_{2t} + \pi_7 X_{3t} + v_{2t}$$

### **Sesgo de simultaneidad producido por MCO**

Todos los supuestos clásicos deben cumplirse para que los estimados MCO sean MELI. Cuando se incumple uno de los supuestos, se debe identificar cual de las propiedades no se mantiene

Cuando se aplica MCO directamente a las ecuaciones estructurales de un sistema simultáneo (denominado ahora Mínimos Cuadrados Directos- MCD) produce estimados de los coeficientes sesgados. Este sesgo se llama sesgo de ecuaciones simultáneas o ***sesgo de simultaneidad***

El sesgo de simultaneidad se refiere al hecho que en un sistema simultáneo, los valores esperados de los coeficientes estructurales estimados ( $b_s$ ) mediante MCO no son iguales a los verdaderos  $\beta_s$

Estos coeficientes estimados son también ***inconsistentes***. Es decir, los valores esperados de las  $b_s$  no

se aproximan a los verdaderos  $\beta_s$  aún cuando el tamaño de la muestra es bastante grande

Por lo tanto, se enfrenta el problema que en un sistema simultáneo:

$$E(b) \neq \beta$$

¿Por qué existe este sesgo de simultaneidad? Se debe recordar que en un sistema de ecuaciones simultáneas, los términos de error ( $\varepsilon_s$ ) tienden a estar correlacionados con las variables endógenas ( $Y_s$ ) cada vez que las  $Y_s$  aparecen como variables explicativas

Se puede seguir el significado de esta correlación (asumiendo coeficientes positivos) a través del siguiente sistema de ecuaciones estructurales:

$$Y_{1t} = \beta_0 + \beta_1 Y_{2t} + \beta_2 X_{1t} + \varepsilon_{1t}$$

$$Y_{2t} = \alpha_0 + \alpha_1 Y_{1t} + \alpha_2 Z_t + \varepsilon_{2t}$$

Puesto que no se puede observar el término error ( $\varepsilon_1$ ) y de desconoce cuando  $\varepsilon_{1t}$  se encuentra encima del promedio, aparecerá como si cada vez que  $Y_1$  esta encima del promedio,  $Y_2$  también.

Como resultado, el procedimiento de estimación de MCO tenderá a atribuir a  $Y_2$  incrementos en  $Y_1$  causados en realidad por el término error  $\varepsilon_1$ , en consecuencia se sobreestimaré  $\beta_1$ .  
***Esta sobreestimación es sesgo de simultaneidad***

Si el término error es anormalmente negativo,  $Y_{1t}$  es menor de lo que hubiese sido de otra manera, causando que  $Y_{2t}$  sea menor de lo que hubiese sido, y el procedimiento de MCO atribuirá el decremento en  $Y_1$  a  $Y_2$ , nuevamente causando la sobreestimación de  $\beta_1$  (induciendo a un sesgo hacia arriba)

Se debe recordar que la causalidad entre  $Y_1$  y  $Y_2$  va en ambas direcciones porque las dos variables son interdependientes

Como resultado, cuando  $\beta_1$  es estimado por MCO no puede interpretarse como el impacto de  $Y_2$  en  $Y_1$ , manteniendo constante  $X$ . En lugar, ahora  $b_1$  mide una mezcla de los efectos de las dos variables endógenas, una sobre la otra

Adicionalmente,  $\beta_2$  se supone que es el efecto de  $X$  sobre  $Y_1$ , manteniendo constante  $Y_2$ . ¿Cómo se puede mantener constante  $Y_2$  cuando se produce un cambio en  $Y_1$ ? Como resultado existe un sesgo potencial en todos los coeficientes estimados en un sistema simultáneo

El incumplimiento del supuesto clásico:  $\text{cov}(\varepsilon_i, X_i) = 0$ , siempre se traducirá en un sesgo en la estimación de  $\beta_1$

## **Mínimos Cuadrados en dos Etapas (MC2E)**

Existe una variedad de técnicas econométricas de estimación disponibles que ayudan a resolver el sesgo y evitar la inconsistencia inherente en la aplicación de MCO a las ecuaciones simultáneas; sin embargo, la alternativa a MCO más utilizada se denomina Mínimos Cuadrados en 2 Etapas (MC2E)

MCO produce sesgos en la estimación de ecuaciones simultáneas porque tales ecuaciones no cumplen el supuesto  $\text{cov}(X_i, \varepsilon_i) = 0$ , de modo que una solución al problema es explorar maneras de evitar el incumplimiento del supuesto

Se podría hacer esto si se encuentra una variable que: (1) es una buena proxy de la variable endógena, y (2) no está correlacionada con el término error

Si se substituye esta nueva variable por la variable endógena que aparece como variable explicativa, la nueva variable no estará correlacionada con el término error y se cumplirá el supuesto  $\text{cov}(X_i, \varepsilon_i) = 0$

Sea el siguiente sistema:

$$Y_{1t} = \beta_0 + \beta_1 Y_{2t} + \beta_2 X_t + \varepsilon_{1t}$$

$$Y_{2t} = \alpha_0 + \alpha_1 Y_{1t} + \alpha_2 Z_t + \varepsilon_{2t}$$

Si se puede encontrar una variable altamente correlacionada con  $Y_2$  pero que no esté correlacionada con  $\varepsilon_1$ , entonces podríamos substituir esta nueva variable por  $Y_2$  en el lado derecho de la primera ecuación en el sistema anterior, por lo tanto se cumpliría el supuesto mencionado más arriba

Esta nueva variable se llama **variable instrumental**. Una variable instrumental reemplaza una variable endógena (cuando es una variable explicativa). Entonces, es una buena proxy para la variable endógena y es independiente del término error

Puesto que no existe una causalidad conjunta entre la variable instrumental y cualquier variable endógena, el uso de la variable instrumental evita el incumplimiento del supuesto  $\text{cov}(X_i, \varepsilon_i) = 0$

¿Cómo se construye o encuentra una variable con estas características? MC2E proporciona una respuesta aproximada

MC2E es un método de creación sistemática de variables instrumentales para reemplazar las variables endógenas donde aparecen como variables explicativas en sistemas de ecuaciones simultáneas

El procedimiento tiene dos etapas:

**Primera etapa:** *correr MCO en las ecuaciones de forma reducidas para cada una de las variables endógenas que aparecen como variables explicativas en el sistema de ecuaciones estructurales*

Puesto que las variables predeterminadas (exógenas y endógenas rezagadas) no están correlacionadas con el error de la forma reducida, los estimados de MCO de los coeficientes de la forma reducida ( $p_s$ ) son insesgados

Estos  $p_s$  pueden utilizarse para calcular estimados de las variables endógenas. Debido a que las  $\pi_s$  no están correlacionadas con las  $\varepsilon_s$ , este procedimiento sólo produce variables instrumentales aproximadas que proporciona estimados de los coeficientes de las ecuaciones estructurales ( $\beta_s$ ) que son consistentes (para muestras grandes) pero sesgados (para pequeñas muestras)

$$\hat{Y}_{1t} = p_0 + p_1 X_t + p_2 Z_t$$

$$\hat{Y}_{2t} = p_3 + p_4 X_t + p_5 Z_t$$

Las  $\hat{Y}_s$  son utilizadas como variables substitutas (proxies) en las ecuaciones estructurales del sistema simultáneo

**Segunda etapa:** substituir los  $\hat{Y}_s$  de la forma reducida en lugar de los  $Y_s$  que aparecen en sólo en el lado derecho de las ecuaciones estructurales y luego estimar estas ecuaciones estructurales revisadas mediante MCO

Esto es, la segunda etapa consiste en estimar las siguientes ecuaciones con MCO:

$$Y_{1t} = \beta_0 + \beta_1 \hat{Y}_{2t} + \beta_2 X_t + \varepsilon_{1t}$$

$$Y_{2t} = \alpha_0 + \alpha_1 \hat{Y}_{1t} + \alpha_2 Z_t + \varepsilon_{2t}$$

Debe notarse que las variables dependientes siguen siendo las variables endógenas originales, sin embargo las substituciones se realizan solamente para las variables endógenas que aparecen en el lado derecho de las ecuaciones estructurales

Si las ecuaciones del segundo estado anteriores son estimadas con MCO, los errores estándar resultantes serán incorrectos, así que se debe utilizar el procedimiento de estimación de MC2E existente en los paquetes econométricos

### **Propiedades de los MC2E**

Este procedimiento tiene varias propiedades:

**Primero**, los estimados de MC2E son todavía sesgados pero ahora son consistentes. Es decir, para muestras pequeñas el valor esperado de  $b$  producido por MC2E no es igual al verdadero  $\beta$ . Pero para muestras cada vez más grandes, el valor esperado de  $b$  se aproxima al verdadero  $\beta$

A medida que el tamaño muestral crece, la varianza de los estimados MCO y MC2E decrecen. Estimados de MCO se vuelven precisos pero de los números equivocados, mientras que los estimados MC2E se vuelven precisos de los números correctos

En consecuencia, a medida que aumenta el tamaño de la muestra, la técnica de MC2E es mejor para la estimación de las ecuaciones simultáneas

**Segundo**, el sesgo producido por MC2E para pequeñas muestras es de signo opuesto al sesgo producido por MCO

Se debe recordar que el sesgo en MCO es positivo, indicando que un  $b$  producido por MCO para un sistema simultáneo es probable que sea más grande que el verdadero  $\beta$

Para MC2E, el sesgo esperado es negativo y, por lo tanto, es probable que el valor de  $b$  estimado, producido por MC2E, sea menor que el verdadero  $\beta$

Los estimados por MC2E, para un conjunto de datos dados, pueden ser más grandes que aquellos producidos por MCO, pero se puede mostrar que es probable que la mayoría de los estimados por MC2E sean menores que los correspondientes estimados por MCO. Para grandes muestras, el sesgo en MC2E es pequeño

**Tercero**, si el ajuste de la ecuación de forma reducida es bastante pobre, entonces MC2E no funcionará muy bien

Se debe recordar que se supone que variable instrumental es una muy buena aproximación (proxy) para la variable endógena. Puesto que el ajuste (medido por  $R^2$ ) de la ecuación de la forma de reducida es pobre, entonces la variable instrumental ya no está altamente correlacionada con la variable endógena original y no hay razón para esperar que MC2E sea efectivo

Como el  $R^2$  de la ecuación de la forma reducida aumenta, la utilidad de MC2E también aumentará

**Cuarto**, si las variables predeterminadas están altamente correlacionadas, entonces MC2E no funcionará bien

La primera etapa de MC2E incluye variables explicativas de ecuaciones estructurales diferentes en la misma forma de

ecuación reducida. Como resultado, es posible la existencia de multicolinealidad severa entre variables explicativas en las ecuaciones de forma reducida provenientes de diferentes ecuaciones estructurales

Cuando esto sucede, un  $\hat{Y}$  producido por una ecuación de forma reducida puede estar altamente correlacionado con las variables exógenas en la ecuación estructural; en consecuencia, la segunda etapa de MC2E también mostrará un alto grado de multicolinealidad y las varianzas de los coeficientes estimados serán altas

Así, cuanto más alta sea el coeficiente de correlación simple entre las variables predeterminadas (o cuando más altos sean los factores de inflación de la varianza) menos precisos serán los estimados provenientes de MC2E

**Quinto**, el uso de la prueba t para contrastar hipótesis es más preciso utilizando estimadores MC2E que utilizando estimadores MCO

A pesar que la prueba t no es exacta para los estimadores MC2E, es suficientemente precisa bajo muchas circunstancias. En contraste, el sesgamiento de los estimadores MCO en sistemas simultáneos implica que sus estadísticos t no son los suficientemente precisos como para contar con ellos para propósitos de contraste de hipótesis

Esto significa que puede ser apropiado el uso de MC2E aún cuando las variables predeterminadas estén altamente correlacionadas

En resumen, MC2E siempre producirá mejores estimadores de los coeficientes de un sistema que aquellos provenientes de MCO. La mayor excepción a esta regla general se origina cuando el ajuste de la ecuación de la forma reducida en cuestión es bastante pobre para una muestra pequeña

### **Ejemplo de Mínimos Cuadrados en 2 Etapas**

El modelo Keynesiano simple de una economía es especificado mediante el siguiente sistema:

$$Y_t = C_t + I_t + G_t + XN_t$$

$$C_t = \beta_0 + \beta_1 YD_t + \beta_2 C_{t-1} + \varepsilon_{1t}$$

$$I_t = \beta_3 + \beta_4 Y_t + \beta_5 r_{t-1} + \varepsilon_{2t}$$

$$r_t = \beta_6 + \beta_7 Y_t + \beta_8 M_t + \varepsilon_{3t}$$

$$YD_t = Y_t - T_t$$

Donde:

$Y_t$  = Producto Interno Bruto (PIB) en el año t

$C_t$  = Consumo personal total en el año t

$I_t$  = Inversión doméstica privada bruta total en el año  $t$

$G_t$  = Compras gubernamentales de bienes y servicios en el año  $t$

$XN_t$  = Exportaciones netas de bienes y servicios (exportaciones menos importaciones) en el año  $t$

$T_t$  = Impuestos en el año  $t$

$r_t$  = tasa de interés (producida en el ámbito comercial) en el año  $t$

$M_t$  = Oferta monetaria en el año  $t$

$YD_t$  = Ingreso disponible en el año  $t$

Todas las variables están en términos reales (medidas en billones de dólares de 1987) excepto la tasa de interés, la cual está medida en términos nominales (porcentaje). Los datos van de 1964 a 1994

Las ecuaciones anteriores son ecuaciones estructurales del sistema, pero sólo las ecuaciones dos, tres y cuatro son estocásticas (comportamiento) y requieren ser estimadas. Las otras dos son identidades

¿Cuáles variables son endógenas y predeterminadas?

Las endógenas son aquellas que están conjuntamente determinadas por el sistema:  $Y_t$ ,  $C_t$ ,  $YD_t$  y  $I_t$

Para ver por qué estas cuatro variables están simultáneamente determinadas, se debe observar que si se cambia una de ellas y se sigue este cambio a través del sistema, el cambio volverá a la variable causal original

Por ejemplo, si  $I_t$  aumenta por alguna razón, esto causará que  $Y_t$  aumente, lo cual retroalimentará a  $I_t$ . Están simultáneamente determinadas

¿Qué pasa con las tasas de interés? ¿Es  $r_t$  una variable endógena? La respuesta es que, hablando estrictamente,  $r_t$  no es endógena en este sistema porque  $r_{t-1}$  (no  $r_t$ ) aparece en la ecuación de la inversión y  $r_t$  aparece sólo una vez en el sistema entero

En consecuencia, no hay retroalimentación simultánea a través de la tasa de interés en este modelo simple. Porque no hay simultaneidad, no hay sesgo de simultaneidad y MCO puede ser utilizado para estimar la ecuación de la tasa de interés. En esencia, esta ecuación no está en el sistema simultáneo.

¿Cuáles son las variables predeterminadas? Si la ecuación de la tasa de interés no está en el sistema simultáneo, entonces las variables predeterminadas son  $G_t$ ,  $XN_t$ ,  $T_t$ ,  $C_{t-1}$  y  $r_{t-1}$ , pero no  $M_t$ , porque la ecuación para  $r_t$  no es parte del sistema

Para resumir, el sistema simultáneo tiene 4 ecuaciones estructurales, 4 variables endógenos y 5 variables predeterminadas

¿Cuál es el contenido económico de las ecuaciones estructurales estocásticas?

La *función de consumo* es una ecuación de rezagos distribuidos, cercana a la hipótesis del ingreso permanente de Milton Friedman: el consumo está basado no en el ingreso presente sino en la percepción que tiene el consumidor sobre sus ingresos a lo largo de su vida. En consecuencia, cambios en el ingreso transitorio no afectarían el consumo. Puesto que parece razonable hipotetizar que las percepciones del ingreso permanente están basadas en niveles pasados de ingreso, un modelo de consumo permanente simple y otro más sofisticado tienen ecuaciones similares. Se espera que  $\beta_1$  y  $\beta_2$  sean positivos

La *función de inversión* incluye un multiplicador y componente del costo del capital. El multiplicador  $\beta_4$  mide el estímulo a la inversión que es generado por un incremento en el PIB. En un modelo Keynesiano, se esperaría que  $\beta_4$  sea positivo. Por otro lado, cuanto más alto el costo del capital, se esperaría menos inversión (manteniendo constante los efectos del multiplicador), principalmente porque la tasa esperada de retorno de las inversiones del capital marginal no es suficiente para cubrir los altos costos del capital. Entonces, se espera

que  $\beta_5$  sea negativa. Toma tiempo planificar e iniciar proyectos de inversión, a pesar que la tasa de interés esta rezagada en un año

La *ecuación de la tasa de interés* es una función de preferencia por liquidez, resuelta para la tasa de interés bajo el supuesto de equilibrio en el mercado de trabajo. En tal situación, un aumento en el PIB incrementará las transacciones de demanda por dinero, manteniendo constante la oferta de dinero, empujando las tasas de interés hacia arriba, de modo que se esperaría que  $\beta_7$  sea positiva. Si la oferta monetaria aumenta, manteniendo constante el PIB, se esperaría que disminuyan las tasas de interés, de modo que  $\beta_8$  sería negativa

Se debe recordar que el modelo keynesiano simple tiene precios constantes como supuesto subyacente

Aplicando el método de MC2E se tiene:

**Etapas 1:** Aún cuando el sistema tiene cuatro variables endógenas, sólo dos de ellas aparecen en el lado derecho de las ecuaciones estocásticas, de modo que sólo dos ecuaciones de forma reducida son estimadas automáticamente por los programas de computación de MC2E. También puede realizarse las estimaciones de manera “manual”, es decir, utilizando MCO en las ecuaciones de forma reducida, para obtener los siguientes resultados:

. reg YD G XN T C\_1 r\_1

Source	SS	df	MS	Number of obs = 31		
Model	13636091.6	5	2727218.32	F( 5, 25) = 2379.17		
Residual	28657.1974	25	1146.2879	Prob > F = 0.0000		
				R-squared = 0.9979		
				Adj R-squared = 0.9975		
				Root MSE = 33.857		
-----						
YD	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
G	-.5475457	.2008534	-2.73	0.012	-.961211	-.1338804
XN	-.6295365	.164692	-3.82	0.001	-.9687261	-.290347
T	-.3431788	.1869255	-1.84	0.078	-.728159	.0418014
C_1	1.237215	.0578294	21.39	0.000	1.118113	1.356316
r_1	-2.033521	4.08872	-0.50	0.623	-10.4544	6.387356
_cons	511.6134	86.24527	5.93	0.000	333.988	689.2389

Durbin-Watson d-statistic (6, 31) = 2.094304

. reg Y G XN T C\_1 r\_1

Source	SS	df	MS	Number of obs = 31		
Model	22629912.5	5	4525982.5	F( 5, 25) = 3948.38		
Residual	28657.1974	25	1146.2879	Prob > F = 0.0000		
				R-squared = 0.9987		
				Adj R-squared = 0.9985		
				Root MSE = 33.857		
-----						
Y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
G	-.5475457	.2008534	-2.73	0.012	-.961211	-.1338804
XN	-.6295365	.164692	-3.82	0.001	-.9687261	-.290347
T	.6568212	.1869255	3.51	0.002	.271841	1.041801
C_1	1.237215	.0578294	21.39	0.000	1.118113	1.356316
r_1	-2.033521	4.08872	-0.50	0.623	-10.4544	6.387356
_cons	511.6134	86.24527	5.93	0.000	333.988	689.2389

Durbin-Watson d-statistic (6, 31) = 2.094304

Las dos formas reducidas anteriores tienen excelentes coeficientes de ajuste global pero seguramente tienen multicolinealidad severa, debido a que tenemos series de tiempo

No es necesario realizar ninguna prueba e multicolinealidad en las ecuaciones de forma reducida ni se

considera eliminar variables como  $r_{t-1}$ , que son estadística y/o teóricamente irrelevantes

El objetivo de la primera etapa de MC2E no es generar ecuaciones de forma reducida estimadas que tengan sentido económico o estadístico, sino general instrumentos de utilidad ( $\hat{Y}$ ,  $\hat{YD}$ ) para substituirlos por las variables endógenas en la segunda etapa

Se estiman las variables instrumentales para las 31 observaciones al reemplazar en las ecuaciones de forma reducida anteriores las 5 variables predeterminadas

**Etapa 2:** Se substituyen  $\hat{Y}$  y  $\hat{YD}$  por las variables endógenas en el lado derechos de las ecuaciones estructurales, es decir:

$$C_t = \beta_0 + \beta_1 \hat{YD}_t + \beta_2 C_{t-1} + \varepsilon_{1t}$$

$$I_t = \beta_3 + \beta_4 \hat{Y}_t + \beta_5 r_{t-1} + \varepsilon_{2t}$$

$$r_t = \beta_6 + \beta_7 \hat{Y}_t + \beta_8 M_t + \varepsilon_{3t}$$

Si se utiliza MCO en las ecuaciones de la segunda etapa anteriores se obtienen los siguientes resultados de MC2E:

. reg C YDhat C\_1

Source	SS	df	MS			
Model	12338712.8	2	6169356.39	Number of obs =	31	
Residual	36199.8081	28	1292.85029	F( 2, 28) =	4771.90	
Total	12374912.6	30	412497.086	Prob > F	= 0.0000	
				R-squared	= 0.9971	
				Adj R-squared	= 0.9969	
				Root MSE	= 35.956	

C	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
YDhat	.4416379	.1811383	2.44	0.021	.0705928	.812683
C_1	.5403089	.1919243	2.82	0.009	.1471698	.933448
_cons	-24.73011	41.09578	-0.60	0.552	-108.911	59.45078

Durbin-Watson d-statistic(3, 31)= 1.485931

. reg I Yhat r\_1

Source	SS	df	MS			
Model	593561.453	2	296780.727	Number of obs =	31	
Residual	63606.3789	28	2271.65639	F( 2, 28) =	130.65	
Total	657167.832	30	21905.5944	Prob > F	= 0.0000	
				R-squared	= 0.9032	
				Adj R-squared	= 0.8963	
				Root MSE	= 47.662	

I	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
Yhat	.1638917	.0101534	16.14	0.000	.1430935	.1846899
r_1	-5.623454	3.180208	-1.77	0.088	-12.13781	.8909062
_cons	33.90486	42.08179	0.81	0.427	-52.29579	120.1055

Durbin-Watson d-statistic(3, 31)= 1.011444

. reg r Yhat M

Source	SS	df	MS			
Model	109.479692	2	54.7398459	Number of obs =	31	
Residual	112.833913	28	4.02978259	F( 2, 28) =	13.58	
Total	222.313604	30	7.41045348	Prob > F	= 0.0001	
				R-squared	= 0.4925	
				Adj R-squared	= 0.4562	
				Root MSE	= 2.0074	

r	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
Yhat	.0084868	.0016449	5.16	0.000	.0051173	.0118563
M	-.0244502	.0047231	-5.18	0.000	-.034125	-.0147754
_cons	-12.66314	4.011918	-3.16	0.004	-20.88118	-4.445101

Durbin-Watson d-statistic(3, 31)= .6297558

Si se hubiesen estimado las ecuaciones estructurales directamente con MCO en lugar de MC2E, se habrían obtenidos los siguientes resultados:

. reg C YD C\_1

Source	SS	df	MS	Number of obs =	31
Model	12349183	2	6174591.52	F( 2, 28) =	6719.46
Residual	25729.5313	28	918.911834	Prob > F	= 0.0000
				R-squared	= 0.9979
				Adj R-squared	= 0.9978
Total	12374912.6	30	412497.086	Root MSE	= 30.314

C	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
YD	.5164862	.1161959	4.44	0.000	.2784697 .7545028
C_1	.4611183	.1232441	3.74	0.001	.2086641 .7135724
_cons	-38.10541	29.77948	-1.28	0.211	-99.10592 22.89509

Durbin-Watson d-statistic(3, 31)= .8926652

. reg I Y r\_1

Source	SS	df	MS	Number of obs =	31
Model	596368.558	2	298184.279	F( 2, 28) =	137.32
Residual	60799.274	28	2171.40264	Prob > F	= 0.0000
				R-squared	= 0.9075
				Adj R-squared	= 0.9009
Total	657167.832	30	21905.5944	Root MSE	= 46.598

I	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
Y	.1641732	.0099203	16.55	0.000	.1438523 .1844941
r_1	-5.637742	3.109188	-1.81	0.081	-12.00662 .7311408
_cons	32.95238	41.12491	0.80	0.430	-51.28818 117.1929

Durbin-Watson d-statistic(3, 31)= .9658097

. reg r Y M

Source	SS	df	MS	Number of obs =	32
Model	125.06873	2	62.5343651	F( 2, 29) =	16.37
Residual	110.795362	29	3.82052972	Prob > F	= 0.0000
				R-squared	= 0.5303
				Adj R-squared	= 0.4979
Total	235.864092	31	7.6085191	Root MSE	= 1.9546

r	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
Y	.0082649	.0014477	5.71	0.000	.0053039 .0112259
M	-.0239728	.0042814	-5.60	0.000	-.0327292 -.0152164
_cons	-12.03228	3.462509	-3.48	0.002	-19.1139 -4.950652

Durbin-Watson d-statistic(3, 32)= .6534176

Quando se comparan los resultados producidos por MCO y MC2E se observa: **Primero**, no hay mucha diferencia entre ambos conjuntos de estimados. Pero si MCO es sesgado,

¿cómo ocurre esto? Cuando el ajuste de las ecuaciones reducidas en la primera etapa es excelente, entonces  $Y$  y  $\hat{Y}$  son virtualmente idénticas y, por lo tanto, la segunda etapa es bastante similar que los estimados de MCO

**Segundo**, se esperaría un sesgo positivo en la estimación de MCO y sesgo negativo pequeño en la estimación de MC2E, pero las diferencias entre MCO y MC2E parecen estar en la dirección esperada sólo la mitad de las veces. Esto puede estar causado por casos de multicolinealidad extrema en las estimaciones de MC2E y por los excelentes ajustes de las ecuaciones de formas reducidas

## **El problema de identificación**

El problema de identificación se refiere a la obtención de estimaciones numéricas de los parámetros de las ecuaciones estructurales a partir de los coeficientes estimados de las ecuaciones de forma reducida

Si se pueden obtener tales estimaciones se dice que la ecuación está identificada; en caso contrario se dice que no está identificada o está subidentificada

Cuando una ecuación está identificada puede estar exactamente identificada o sobreidentificada. Exactamente identificada significa que se pueden obtener valores numéricos únicos de los parámetros estructurales. Mientras que cuando

está sobreidentificada se pueden obtener más de un valor numérico para los parámetros de las ecuaciones estructurales

Este problema surge debido a que diferentes conjuntos de coeficientes estructurales pueden ser compatibles con la misma información. Es decir, una ecuación de forma reducida dada puede ser compatible con diferentes ecuaciones estructurales

En el ejemplo de la oferta y demanda, dada la información sobre precios y cantidades y ningún dato adicional, no hay manera de garantizar que la estimación sea de la función de oferta o demanda; porque  $P_t$  y  $Q_t$  representan sólo puntos de intersección de las curvas de demanda y oferta debido a la condición de equilibrio. Es decir,

$$Q_{Dt} = \alpha_0 + \alpha_1 P_t + \varepsilon_{1t}$$

$$Q_{St} = \beta_0 + \beta_1 P_t + \varepsilon_{2t}$$

A pesar de haber etiquetado una ecuación como demanda y la otra como oferta, la computadora no será capaz de identificarlas a partir de los datos disponibles porque las variables del lado derecho y del izquierdo son las mismas en ambas ecuaciones. Sin la presencia de alguna variable predeterminada para distinguir entre ambas ecuaciones, sería imposible distinguir entre oferta y demanda

Si se añade una variable predeterminada a la ecuación de la oferta, por ejemplo, la ecuación vuelve:

$$Q_{St} = \beta_0 + \beta_1 P_t + \beta_2 Z_t + \varepsilon_{2t}$$

Por lo tanto, cada vez que  $Z$  (condiciones climáticas u otros factores externos) cambia, la curva de oferta se desplazará en el tiempo, pero la demanda permanece relativamente estable, por lo que los puntos dispersos trazan una curva de demanda, entonces se dice que la curva de demanda ha sido identificada

Una interpretación similar se produce para la demanda, se requiere información adicional sobre la naturaleza de dicha curva, por ejemplo, la demanda se desplaza en el tiempo debido a cambios en el ingreso, gustos, preferencias, etc., pero la oferta permanece constante ante estos cambios. En esta situación se dice que se ha identificado la curva de oferta

La manera de identificar ambas curvas es tener al menos una variable predeterminada en cada ecuación pero que no está en la otra, como por ejemplo:

$$Q_{Dt} = \alpha_0 + \alpha_1 P_t + \alpha_2 X_t + \varepsilon_{1t}$$

$$Q_{St} = \beta_0 + \beta_1 P_t + \beta_2 Z_t + \varepsilon_{2t}$$

Ahora, cuando  $Z$  cambia, la curva de oferta se desplaza y se puede identificar la curva de demanda de los datos sobre el equilibrio de precios y cantidades. Pero cuando  $X$  cambia, la curva de demanda se desplaza y se puede identificar la curva de oferta a partir de los datos. Si  $X$  y  $Z$  están altamente correlacionadas, tendremos problemas de estimación

La identificación es una precondition para la aplicación de MC2E a ecuaciones simultáneas. Es decir, el método de MC2E no puede aplicarse a una ecuación de forma reducida a menos que sea **identificada**

Por consiguiente, antes de estimar cualquier ecuación en un sistema simultáneo, el econométrista debe tratar el problema de identificación. Una vez que una ecuación se encuentra que es identificada, entonces puede ser estimada con MC2E pero si una ecuación no es identificada (subidentificada), entonces no puede ser utilizada MC2E ni importa cuán grande sea la muestra

Es importante señalar que una ecuación identificada (y que puede ser estimada por MC2E) no asegura que los estimados MC2E resultantes sean buenos.

## **Reglas de identificación**

Como se vio anteriormente, siempre es posible utilizar las ecuaciones de forma reducida para determinar la identificación de una ecuación en un sistema de ecuaciones simultáneas, a pesar que puede ser un trabajo laborioso y que toma mucho tiempo

Para evitar este trabajo se llevan a cabo las pruebas de **condiciones de orden y rango de identificación**.

### **Condición de orden**

La condición de orden es un método sistemático para determinar si una ecuación particular en un sistema simultáneo tiene el potencial de ser identificado. La condición de orden es una condición necesaria pero no suficiente

La condición necesaria para que una ecuación esté identificada es que el número de variables predeterminadas en el sistema sea mayor o igual que el número de coeficientes de pendiente en la ecuación de interés. Es decir,

Número predeterminadas = Número coeficientes de pendiente

(en el sistema simultáneo)      (en la ecuación)

De manera equivalente se puede escribir, en un modelo de M ecuaciones simultáneas, una ecuación está identificada si el número de variables predeterminadas excluidas en esta ecuación no debe ser menor que el número de variables endógenas incluidas menos 1, es decir,

$$K - k \geq m - 1$$

Pero si  $K - k = m - 1$ , entonces la ecuación está exactamente identificada, y si  $K - k > m - 1$  la ecuación estará sobreidentificada.

Donde:

$M$ = número de variables endógenas en el modelo

$m$ = número de variables endógenas en una ecuación dada

$K$ = número de variables predeterminadas en el modelo

$k$ = número de variables predeterminada en una ecuación dada

Las variables endógenas son aquellas que están conjuntamente determinadas en el sistema en el periodo actual. Las variables predeterminadas son las exógenas más las endógenas rezagadas que podrían estar en el modelo

## Ejemplos

Sea el modelo de oferta y demanda de las bebidas gaseosas:

$$Q_{Dt} = \alpha_0 + \alpha_1 P_t + \alpha_2 X_{1t} + \alpha_3 X_{2t} + \varepsilon_{Dt}$$

$$Q_{St} = \beta_0 + \beta_1 P_t + \beta_2 X_{3t} + \varepsilon_{St}$$

El modelo tiene dos variables endógenas (Q y P) y tres variables exógenas ( $X_1$ ,  $X_2$  y  $X_3$ )

Para la primera ecuación se tiene que  $M=2$ ,  $K=3$ ,  $m=2$ ,  $k=2$ , por lo tanto:

$$3 - 2 >? 2 - 1 \quad \text{ó} \quad 1 = 1$$

Por lo tanto, la primera ecuación está **exactamente identificada**. También se puede ver que puesto el número de variables predeterminadas ( $X_1$ ,  $X_2$  y  $X_3$ ) es igual al número de coeficientes de pendiente de la primera ecuación ( $\alpha_1$ ,  $\alpha_2$ ,  $\alpha_3$ ), en consecuencia, la ecuación está exactamente identificada

Para la segunda ecuación se tiene que  $M=2$ ,  $K=3$ ,  $m=2$ ,  $k=1$ , por lo tanto:

$$3 - 1 >? 2 - 1 \quad \text{ó} \quad 2 > 1$$

Por lo tanto, la segunda ecuación está **sobreidentificada**. También se puede ver que puesto el número de variables predeterminadas ( $X_1$ ,  $X_2$  y  $X_3$ ) es mayor al número de coeficientes de pendiente de la ecuación ( $\beta_1$ ,  $\beta_2$ ), en consecuencia, la ecuación está sobreidentificada

En consecuencia, el método de MC2E puede aplicarse al sistema porque ambas ecuaciones están identificadas (exactamente identificadas y/o sobreidentificadas)

Un sistema más complicado es el modelo macroeconómico simple:

$$Y_t = C_t + I_t + G_t + XN_t$$

$$C_t = \beta_0 + \beta_1 YD_t + \beta_2 C_{t-1} + \varepsilon_{1t}$$

$$I_t = \beta_3 + \beta_4 Y_t + \beta_5 r_{t-1} + \varepsilon_{2t}$$

$$YD_t = Y_t - T_t$$

El modelo tiene 5 variables predeterminadas ( $G_t$ ,  $XN_t$ ,  $T_t$ ,  $C_{t-1}$ ,  $r_{t-1}$ ) y 4 endógenas ( $Y_t$ ,  $C_t$ ,  $I_t$ ,  $YD_t$ )

La ecuación de consumo tiene dos coeficientes de pendiente a ser estimados ( $\beta_1$ ,  $\beta_2$ ), de modo que esta ecuación está sobreestimada ( $5 > 2$ ), así que cumple la condición de orden de identificación

La ecuación de la inversión también tiene dos coeficientes de pendiente a ser estimados ( $\beta_4$ ,  $\beta_5$ ), de modo que esta ecuación está también sobreestimada ( $5 > 2$ ), de modo que cumple la condición de orden de identificación