

# ECONOMETRIA

## Tema 3: El modelo de regresión lineal múltiple

César Alonso

Universidad Carlos III de Madrid



- En la mayoría de las relaciones económicas intervienen más de dos variables. Los factores que afectan al fenómeno económico objeto de estudio suelen ser múltiples.
- Esto supone una limitación en la aplicación del modelo de regresión lineal simple  $Y = \beta_0 + \beta_1 X_1 + \varepsilon_1$  en el análisis empírico.
- Aunque nuestro interés fundamental radique en el efecto concreto de una determinada variable  $X_1$  sobre un fenómeno económico  $Y$ , generalmente entran en juego factores adicionales  $X_2, \dots, X_K$ .
  - Dichos factores adicionales están, generalmente, relacionados con  $X_1$ .
  - Recordemos que todos los factores no incorporados al modelo están contenidos en el término inobservable (la parte no explicada) del modelo,  $\varepsilon_1$ .



- En la medida en que  $X_1$  no sea independiente de  $X_2, \dots, X_K$ , tendremos que, en el modelo simple, el término inobservable no verificará  $E(\varepsilon_1|X_1) = 0$ .
- En tal caso, debemos incorporar los factores adicionales  $X_2, \dots, X_K$  al modelo para poder **aislar el efecto causal** de dicha variable
- Al **controlar por varios factores**, en el modelo de regresión lineal múltiple

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_K X_K + \varepsilon$$

será más fácil que se cumpla que su término inobservable  $\varepsilon$  es independiente de dichos factores que en el modelo simple.



- En el modelo de regresión lineal múltiple, la pendiente  $\beta_j$  ( $j = 1, \dots, K$ ) se interpreta como el **efecto parcial** o **efecto ceteris paribus** de un cambio en la variable asociada  $X_j$ 
  - Si los supuestos que veremos a continuación se cumplen, dicha interpretación es correcta aunque los datos no procedan de un experimento
  - En tales condiciones, el modelo de regresión múltiple permite reproducir las condiciones de un experimento controlado (mantener los restantes factores fijos) en un contexto no experimental.



- **Ejemplo 1:** Efecto causal de la educación sobre el salario
  - $Y = \text{Salario}$   $X_1 = \text{Educación}$
  - Nuestro interés fundamental radica en el efecto de la educación.
- Pero sabemos que otras variables afectan también al salario. Por ejemplo, sean  $X_2 = \text{Sexo}$ ,  $X_3 = \text{Experiencia (laboral)}$ ,  $X_4 = \text{Capacidad (que suponemos medible)}$ .

$$\text{Salario} = \beta_0 + \beta_1 \text{Educación} + \beta_2 \text{Sexo} + \beta_3 \text{Experiencia} + \beta_4 \text{Capacidad} + \varepsilon$$

- Cabe esperar que Educación no sea independiente de Experiencia, Sexo y Capacidad.



- En ese caso, al *variar* el nivel de Educación también varían Experiencia, Sexo y Capacidad:
  - Las proporciones de hombres y mujeres puede diferir por niveles de educación
  - La Experiencia puede tener una distribución diferente por niveles de educación.  
(Si adquirir más Educación retrasa la incorporación al mercado de trabajo, esperaríamos que  $C(X_1, X_2) < 0$ ).
  - La Capacidad puede tener una distribución diferente por niveles de educación.  
(Si los individuos con mayor Capacidad tienden a adquirir más Educación, esperaríamos que  $C(X_1, X_4) > 0$ ).
- $\beta_1$  es el parámetro de mayor interés.
  - En la regresión múltiple, nos aseguramos de que  $\beta_1$  captura el efecto parcial de la educación manteniendo otros factores, en este caso Experiencia, Sexo y Capacidad, fijos.
  - En la regresión simple, Experiencia, Sexo y Capacidad forman parte del término inobservable  $\varepsilon_1$ , sobre el que no tenemos control.



- **Ejemplo 2** (Wooldridge): Efecto del gasto en educación sobre el rendimiento escolar
  - Supongamos que disponemos de datos de distintas escuelas públicas en distintos distritos, para las que observamos, para un curso determinado, la calificación media *avgscore* y el gasto en educación por alumno *expend*
  - Nuestro interés radica en cuantificar el efecto del gasto en educación por alumno *expend* (que es una herramienta de política pública) en el rendimiento escolar *avgscore*.
  - Pero el entorno familiar también afecta al rendimiento escolar, que a su vez está correlacionado con la renta media de las familias *avginc*.
  - ADEMÁS, el gasto per capita en educación tiende a crecer con la renta de las familias *avginc* (porque el gasto en educación depende de la capacidad fiscal del distrito).
  - En la regresión simple de *avgscore* sobre *expend*, el término de error incluirá, entre otros factores no controlados, *avginc*.
    - En tal caso, es difícil defender que el término inobservable del modelo simple no va a variar cuando varíe *expend*.



# El modelo de regresión lineal múltiple

## Supuestos

En el Modelo Lineal de Regresión Múltiple suponemos:

[1.] **Linealidad en los parámetros**  $E(\varepsilon | X_1, X_2, \dots, X_K) = 0$ .

(Para cualquier combinación de valores de  $X_1, X_2, \dots, X_K$ , la media del término inobservable es siempre la misma e igual a 0)

### Implicaciones:

- $E(\varepsilon) = 0$  (por la ley de esperanzas iteradas)
- $C(h(X_j), \varepsilon) = 0 \Rightarrow$  (en particular)  $C(X_j, \varepsilon) = 0$  ( $j = 1, \dots, K$ ).





### [3.] Homocedasticidad condicional:

$$\begin{aligned} V(\varepsilon | X_1, X_2, \dots, X_K) &= \sigma^2 \\ \Rightarrow V(Y | X_1, X_2, \dots, X_K) &= \sigma^2 \end{aligned}$$

(La **varianza de  $\varepsilon$**  y/o de  $Y$  **cada una de las subpoblaciones** asociadas a cualquier combinación de valores de  $X_1, X_2, \dots, X_K$  es constante)( $X_1, X_2, \dots, X_K$ ) no forman una combinación lineal exacta (**Ausencia de Multicolinealidad Exacta**)



# El modelo de regresión lineal múltiple

## Supuestos

Nótese que los supuestos **1.** y **2.** implican que: Tenemos una **Función Esperanza Condicional (FEC)** lineal:

$$E(Y | X_1, X_2, \dots, X_K) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_K X_K$$

La FEC nos proporciona, para cada combinación de valores de  $(X_1, X_2, \dots, X_K)$ , la **media de  $Y$  en la subpoblación** correspondiente dicha combinación de valores. La FEC nos proporciona la **mejor predicción posible** en el sentido de que minimiza  $E(\varepsilon^2)$ , siendo  $\varepsilon =$  error de predicción  $= Y - c(X_1, X_2, \dots, X_K)$ . La FEC, al igual que ocurría en el modelo de regresión lineal simple, coincide con el  $L(Y | X_1, X_2, \dots, X_K)$ , que es el mejor predictor lineal en el sentido de que minimiza  $E(\varepsilon^2)$ , siendo  $\varepsilon = Y - (\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_K X_K)$ .

3. Por tanto, las condiciones de primer orden que determinan los  $\beta$ 's son:

$$E(\varepsilon) = 0, \quad C(X_1, \varepsilon) = 0, \quad \dots, \quad C(X_K, \varepsilon) = 0.$$



# El modelo de regresión lineal múltiple

## El modelo de regresión lineal con dos variables

- Vamos a considerar el modelo de regresión múltiple más sencillo posible (con sólo 2 variables).

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \varepsilon$$

- Para ilustrarlo, supongamos que la población de interés está compuesta por individuos de edad, experiencia laboral y capacidad similares.
- Consideramos las siguientes variables:
  - $Y =$  Salario
  - $X_1 =$  Educación
  - $X_2 =$  Sexo =  $\begin{cases} 1 & \text{si es mujer} \\ 0 & \text{si es hombre} \end{cases}$



# El modelo de regresión lineal múltiple

## El modelo de regresión lineal con dos variables

- Tenemos que:

$$E(Y|X_1, X_2) = \beta_0 + \beta_1 X_1 + \beta_2 X_2$$

de manera que

$$E(Y|X_1, X_2 = 0) = \beta_0 + \beta_1 X_1$$


$$E(Y|X_1, X_2 = 1) = \beta_0 + \beta_2 + \beta_1 X_1$$



# El modelo de regresión lineal múltiple

## El modelo de regresión lineal con dos variables

- Como se ve en el gráfico, si  $\beta_2 < 0$ ,  $E(Y|X_1, X_2 = 0)$  es una recta paralela a  $E(Y|X_1, X_2 = 1)$  y por encima de ésta.



# El modelo de regresión lineal múltiple

## Interpretación de los coeficientes en el modelo de regresión múltiple

- Si todas las variables excepto  $X_j$  permanecen constantes,

$$\Delta E(Y|X_1, X_2, \dots, X_K) = \beta_j \Delta X_j$$

de manera que

$$\beta_j = \frac{\Delta E(Y|X_1, X_2, \dots, X_K)}{\Delta X_j}$$

- $\beta_j$ : Cuando  $X_j$  varía en una unidad (permaneciendo el resto de las variables constantes),  $Y$  varía, en promedio, en  $\beta_j$  unidades.
- Nótese que: la regresión múltiple  $Y = E(Y|X_1, X_2, \dots, X_K) + \varepsilon$  responde a una pregunta diferente que las (teóricas) regresiones simples  $Y = E(Y|X_1) + \varepsilon_1, \dots, Y = E(Y|X_K) + \varepsilon_K$



# El modelo de regresión lineal múltiple

## Interpretación de los coeficientes en el modelo de regresión múltiple

- En nuestro ejemplo:

- $E(Y|X_1, X_2) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 =$  Valor esperado del salario para unos valores dados de educación y sexo.
  - $\beta_1 =$  Incremento en el salario medio asociado a un año adicional de educación *manteniendo el sexo constante* (es decir, para individuos del mismo sexo).
- $E(Y|X_1) = \gamma_0 + \gamma_1 X_1 =$  Valor esperado del salario para unos valores dados de educación.
  - $\gamma_1 =$  Incremento en el salario medio asociado a un año adicional de educación, pero *sin mantener el sexo constante* (es decir, ignorando que al comparar dos distribuciones con distintos años de educación, las proporciones de hombres y mujeres pueden ser distintas).



# El modelo de regresión lineal múltiple

## Regresión larga vs. regresión corta

- Continuamos con el modelo de regresión lineal múltiple más sencillo, con dos variables, que denotaremos como **Regresión larga** poblacional,

$$Y = E(Y|X_1, X_2) + \varepsilon$$

donde

$$E(Y|X_1, X_2) = L(Y|X_1, X_2) = \beta_0 + \beta_1 X_1 + \beta_2 X_2$$

- Los parámetros  $\beta_0$ ,  $\beta_1$  y  $\beta_2$  han de verificar:

$$E(\varepsilon) = 0 \Rightarrow \beta_0 = E(Y) - \beta_1 E(X_1) - \beta_2 E(X_2) \quad (1)$$

$$C(X_1, \varepsilon) = 0 \Rightarrow \beta_1 V(X_1) + \beta_2 C(X_1, X_2) = C(X_1, Y) \quad (2)$$

$$C(X_2, \varepsilon) = 0 \Rightarrow \beta_1 C(X_1, X_2) + \beta_2 V(X_2) = C(X_2, Y) \quad (3)$$





# El modelo de regresión lineal múltiple

## Regresión larga vs. regresión corta

- De (2) y (3) tenemos:

$$\beta_1 = \frac{V(X_2)C(X_1, Y) - C(X_1, X_2)C(X_2, Y)}{V(X_1)V(X_2) - [C(X_1, X_2)]^2}$$
$$\beta_2 = \frac{V(X_1)C(X_2, Y) - C(X_1, X_2)C(X_1, Y)}{V(X_1)V(X_2) - [C(X_1, X_2)]^2}$$

- Nótese que en el caso de que  $C(X_1, X_2) = 0$ :

$$\beta_1 = \frac{C(X_1, Y)}{V(X_1)} \quad (\text{pendiente de } L(Y|X_1))$$
$$\beta_2 = \frac{C(X_2, Y)}{V(X_2)} \quad (\text{pendiente de } L(Y|X_2))$$



# El modelo de regresión lineal múltiple

## Regresión larga vs. regresión corta

- Supongamos que estamos particularmente interesados en el efecto de  $X_1$  sobre  $Y$ .
  - Pero nos preocupa que  $X_1$  y  $X_2$  puedan estar relacionadas.
  - En tal caso, el coeficiente del modelo de regresión lineal simple NO nos proporciona el efecto de interés.
- Sea el Modelo de Regresión Lineal Simple, que denotamos como **Regresión corta** poblacional,

$$L(Y|X_1) = \gamma_0 + \gamma_1 X_1$$

Los parámetros  $\gamma_0$  y  $\gamma_1$  han de verificar:

$$E(\varepsilon_1) = 0 \Rightarrow \gamma_0 = E(Y) - \gamma_1 E(X_1) \quad (4)$$

$$C(X_1, \varepsilon_1) = 0 \Rightarrow \gamma_1 = C(X_1, Y) / V(X_1) \quad (5)$$

- (Obviamente, podríamos considerar otra regresión corta poblacional correspondiente a la proyección lineal de  $Y$  sobre  $X_2$ , con argumentos similares)



# El modelo de regresión lineal múltiple

## Regresión larga vs. regresión corta

- A partir de (2) y de (5) tenemos que:

$$\gamma_1 = \frac{C(X_1, Y)}{V(X_1)} = \frac{\beta_1 V(X_1) + \beta_2 C(X_1, X_2)}{V(X_1)} = \beta_1 + \beta_2 \frac{C(X_1, X_2)}{V(X_1)}$$

Nótese que:

- $\gamma_1 = \beta_1$  solamente si  $C(X_1, X_2) = 0$  ó si  $\beta_2 = 0$ .
- $\frac{C(X_1, X_2)}{V(X_1)}$  es la pendiente de  $L(X_2|X_1)$  :

$$L(X_2|X_1) = \delta_0 + \delta_1 X_1$$



# Estimación MCO en el modelo de regresión lineal múltiple

- Nuestro objetivo consiste en estimar los parámetros poblacionales, los “betas”, a partir de un conjunto de datos.
- Supondremos que nuestros datos  $(y_i^*, x_{1i}^*, x_{2i}^*, \dots, x_{ki}^*)$ , con  $i = 1, \dots, n$ , son una realización de una **muestra aleatoria** de tamaño  $n$  de una población,  $(Y_i, X_{1i}, X_{2i}, \dots, X_{ki})$ .
- Sea el modelo:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_K X_K + \varepsilon$$

- Dada una muestra aleatoria de tamaño  $n$  de la población, podemos escribir:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_K X_{Ki} + \varepsilon_i \quad i = 1, \dots, n$$

donde para todo  $i = 1, \dots, n$ , se cumplen los supuestos 1. a 4



# Estimación MCO en el modelo de regresión lineal múltiple

- Vamos a ver cómo podemos obtener estimadores de los parámetros  $\beta_0, \beta_1, \dots, \beta_K$  y  $\sigma^2$ , denotados como  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_K$  y  $\hat{\sigma}^2$ .
- Partiremos igualmente del principio de analogía para proponer estimadores, generalizando el resultado del modelo de regresión lineal simple al caso del modelo de regresión múltiple
- La obtención de los estimadores requiere también resolver un sistema de ecuaciones (aunque analíticamente la resolución es más compleja).
- Los parámetros poblacionales  $\beta_0, \beta_1, \dots, \beta_K$  son aquellos que resuelve el problema

$$\min_{\beta_0, \beta_1, \dots, \beta_K} E(\varepsilon^2),$$

donde  $\varepsilon = Y - \beta_0 - \beta_1 X_1 - \beta_2 X_2 - \dots - \beta_K X_K$



- Para estimar dichos parámetros, en lugar del error  $\varepsilon_i$  (inobservable), podemos utilizar el **residuo** (desviación entre el valor observado y el valor predicho) como,

$$\hat{\varepsilon}_i = Y_i - \hat{Y}_i = Y_i - (\hat{\beta}_0 + \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \cdots + \hat{\beta}_K X_{Ki})$$

donde  $\hat{Y}_i$  es el **valor predicho** o **valor ajustado**, y definir el criterio MCO, que es el análogo muestral del criterio  $\min E(\varepsilon^2)$ ,

$$\min_{\beta_0, \beta_1, \dots, \beta_K} \frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_i^2,$$



- Las condiciones de primer orden son:

$$\sum_i \hat{\varepsilon}_i = 0, \quad \sum_i \hat{\varepsilon}_i X_{1i} = 0, \quad \dots, \quad \sum_i \hat{\varepsilon}_i X_{Ki} = 0$$

o, de forma equivalente, definiendo  $x_{ji} = (X_{ji} - \bar{X}_j)$ ,  $j = 1, \dots, K$ .

$$\left. \begin{array}{l} \frac{1}{n} \sum_i \hat{\varepsilon}_i = 0 \\ \frac{1}{n} \sum_i \hat{\varepsilon}_i X_{1i} = 0 \\ \quad \quad \quad \vdots \\ \frac{1}{n} \sum_i \hat{\varepsilon}_i X_{Ki} = 0 \end{array} \right\} \begin{array}{l} \text{(media muestral de los residuos 0)} \\ \text{(covarianza muestral 0 entre } X_j \text{ y } \hat{\varepsilon}) \end{array}$$



- Nótese que estas condiciones de primer orden son el **análogo muestral** de las condiciones de primer orden para el modelo de regresión clásico referido a los  $\beta$ 's en la población:

$$\left. \begin{array}{l} E(\varepsilon) = 0 \\ C(X_1, \varepsilon) = 0 \\ \vdots \\ C(X_K, \varepsilon) = 0 \end{array} \right\} \begin{array}{l} \text{(media poblacional de los errores 0)} \\ \text{(covarianza poblacional 0 entre } X_j \text{ y } \varepsilon) \end{array}$$





- El sistema de ecuaciones normales es ahora:

$$\begin{cases} n\hat{\beta}_0 + \hat{\beta}_1 \sum_i X_{1i} + \hat{\beta}_2 \sum_i X_{2i} + \cdots + \hat{\beta}_K \sum_i X_{Ki} = \sum_i Y_i \\ \hat{\beta}_1 \sum_i x_{1i}^2 + \hat{\beta}_2 \sum_i x_{2i}x_{1i} + \cdots + \hat{\beta}_K \sum_i x_{Ki}x_{1i} = \sum_i y_i x_{1i} \\ \vdots \\ \hat{\beta}_1 \sum_i x_{1i}x_{Ki} + \hat{\beta}_2 \sum_i x_{2i}x_{Ki} + \cdots + \hat{\beta}_K \sum_i x_{Ki}^2 = \sum_i y_i x_{Ki} \end{cases}$$

- En general, para  $K$  variables, tendremos un sistema con  $K + 1$  ecuaciones lineales, donde las  $K + 1$  incógnitas son los coeficientes  $\hat{\beta}$ 's de la regresión.
- El sistema tendrá solución única siempre que se cumpla el supuesto 4., es decir: que no exista multicolinealidad exacta. (Si existiera multicolinealidad exacta, el sistema tendría infinitas soluciones)



- Podemos ver el álgebra de la estimación MCO para el modelo con dos variables.
- Los parámetros poblacionales tienen la forma:

$$\begin{aligned}\beta_0 &= E(Y) - \beta_1 E(X_1) - \beta_2 E(X_2) \\ \beta_1 &= \frac{V(X_2)C(X_1, Y) - C(X_1, X_2)C(X_2, Y)}{V(X_1)V(X_2) - [C(X_1, X_2)]^2} \\ \beta_2 &= \frac{V(X_1)C(X_2, Y) - C(X_1, X_2)C(X_1, Y)}{V(X_1)V(X_2) - [C(X_1, X_2)]^2}\end{aligned}$$



- Aplicando el principio de analogía, tenemos que

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}_1 - \hat{\beta}_2 \bar{X}_2$$

$$\hat{\beta}_1 = \frac{s_2^2 s_{1y} - s_{12} s_{2y}}{s_1^2 s_2^2 - s_{12}^2}$$

$$\hat{\beta}_2 = \frac{s_1^2 s_{2y} - s_{12} s_{1y}}{s_1^2 s_2^2 - s_{12}^2}$$



- donde

$$s_1^2 = \frac{1}{n} \sum_i (X_{1i} - \bar{X}_1)^2$$

$$s_{1y} = \frac{1}{n} \sum_i (X_{1i} - \bar{X}_1) (Y_i - \bar{Y})$$

$$s_{12} = \frac{1}{n} \sum_i (X_{1i} - \bar{X}_1) (X_{2i} - \bar{X}_2) = s_{21}$$

$$s_2^2 = \frac{1}{n} \sum_i (X_{2i} - \bar{X}_2)^2$$

$$s_{2y} = \frac{1}{n} \sum_i (X_{2i} - \bar{X}_2) (Y_i - \bar{Y})$$

- Los estimadores  $\hat{\beta}_1$  y  $\hat{\beta}_2$  de las pendientes miden los efectos parciales estimados de  $X_1$  y  $X_2$ , respectivamente, en el valor medio de  $Y$ .



- Al igual que en el modelo de regresión simple, los estimadores MCO del modelo de regresión múltiple verifican las propiedades de:
  - Linealidad en las observaciones de  $Y$  (por definición del estimador MCO)
  - Insesgadez (bajo los supuestos **1.** y **2.** y **4.**)
  - Teorema de Gauss-Markov: Bajo los supuestos **1.** a **4.**,  $\hat{\beta}_0$ ,  $\hat{\beta}_1, \dots, \hat{\beta}_K$  son los de menor varianza entre los estimadores lineales e insesgados.
  - Consistencia
- La justificación de estas propiedades es similar a la del caso del modelo de regresión lineal simple.



- Además de los supuestos **1.** y **2.**, utilizaremos el supuesto **3.**  
( $V(\varepsilon|X_1, X_2, \dots, X_K) = \sigma^2$  para todo  $X$ ).
- $V(\hat{\beta}_j) = \frac{\sigma^2}{nS_j^2(1-R_j^2)} = \frac{\sigma^2}{\sum_i x_{ji}^2(1-R_j^2)}$ , ( $j = 1, \dots, K$ ) donde
  - $S_j^2 = \frac{1}{n}(\sum_i x_{ji}^2) = \frac{1}{n}(\sum_i (X_{ji} - \bar{X}_j)^2)$
  - $R_j^2$  es el coeficiente de determinación de la proyección lineal muestral de  $X_j$  sobre las restantes variables explicativas  $X_{1i}, X_{2i}, \dots, X_{(j-1)i}, X_{(j+1)i}, \dots, X_{Ki}$ :

$$X_{ji} = \theta_0 + \theta_1 X_{1i} + \theta_2 X_{2i} + \dots + \theta_{j-1} X_{(j-1)i} + \theta_{j+1} X_{(j+1)i} + \dots + \theta_K X_{Ki} + u_i$$



- $R_j^2$  mide la proporción de información de la variable  $X_j$  que ya está contenida en las demás variables.
- Por tanto  $(1 - R_j^2)$  mide la proporción de información distinta de la proporcionada por las restantes variables que aporta la variable  $X_j$ .
  - No es posible que  $R_j^2 = 1$ , porque en ese caso  $X_j$  sería una combinación lineal exacta de las restantes variables (lo que se descarta por el supuesto **4.**).  
Pero si  $R_j^2$  estuviera cercano a 1,  $V(\hat{\beta}_j)$  se dispararía.
  - Por el contrario, si  $R_j^2 = 0$ , lo que ocurre si la correlación de  $X_j$  con las restantes variables es 0, entonces la varianza sería la mínima posible.



- Intuitivamente:

- Cuanto mayor es  $S_j^2 = \frac{1}{n} \sum_i x_{ji}^2$ , mayor es la variabilidad muestral de  $X_j$ , y mayor es la precisión del estimador.
- Cuanto mayor es el tamaño muestral  $n$ , mayor es la precisión del estimador (al mejorar el grado de representatividad de la muestra).
- Cuanto mayor es  $R_j^2$ , menor es la precisión del estimador.

- Demostración: Véase Wooldridge.

(Sin pérdida de generalidad, dado que el orden de las variables explicativas es arbitrario, la prueba es para  $\hat{\beta}_1$ ; la prueba para  $\hat{\beta}_2, \dots, \hat{\beta}_K$  es análoga).





# Propiedades de los estimadores MCO

## Estimación de la varianza

- El problema de estimación de  $\sigma^2$  es similar al caso del modelo de regresión lineal simple.
- El problema es que los errores  $\varepsilon_i$  ( $i = 1, \dots, n$ ) son inobservables.
- Una vez estimado el modelo por MCO, observamos los residuos  $\hat{\varepsilon}_i$ :

$$\hat{\varepsilon}_i = Y_i - \left( \hat{\beta}_0 + \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \dots + \hat{\beta}_K X_{Ki} \right)$$

- Utilizando los residuos como análogos muestrales de los errores (inobservables), podemos calcular como estimador de  $\sigma^2$ :

$$\tilde{\sigma}^2 = \frac{\sum_i \hat{\varepsilon}_i^2}{n}.$$



# Propiedades de los estimadores MCO

## Estimación de la varianza

- Este estimador sí es factible, pero es sesgado. La razón es que, los residuos verifican  $K + 1$  restricciones lineales,

$$\sum_i \hat{\varepsilon}_i = 0, \quad \sum_i \hat{\varepsilon}_i X_{1i} = 0, \quad \dots, \quad \sum_i \hat{\varepsilon}_i X_{Ki} = 0$$

de manera que sólo hay  $(n - K - 1)$  residuos independientes (lo que se conoce como **grados de libertad**).

- Alternativamente, podemos obtener un estimador insesgado (que para  $n$  grande es muy similar a  $\tilde{\sigma}^2$ ):

$$\hat{\sigma}^2 = \frac{\sum_i \hat{\varepsilon}_i^2}{n - K - 1}.$$

- Tanto  $\tilde{\sigma}^2$  como  $\hat{\sigma}^2$  son estimadores consistentes de  $\sigma^2$ .
- En general, para tamaños muestrales moderados, es irrelevante cuál de los dos estimadores utilizar, porque siempre que  $n$  no sea muy pequeño, proporcionan estimaciones numéricas muy parecidas.



# Propiedades de los estimadores MCO

## Estimación de las varianzas de los estimadores MCO

- De igual modo, hemos de emplear un estimador consistente de  $\sigma^2$  y sustituir en la expresión de la varianza, obteniendo

$$\widehat{V}(\widehat{\beta}_j) = \frac{\widehat{\sigma}^2}{nS_j^2(1 - R_j^2)}$$

donde  $S_j^2$  es la varianza muestral de la variable  $X_j$ ,

$$S_j^2 = \frac{1}{n} \sum_i (X_{ji} - \bar{X}_j)^2.$$



# Medidas de bondad del ajuste

## Error estándar de la regresión

- Tal y como argumentamos en la regresión lineal simple, podemos utilizar la raíz cuadrada de  $\hat{\sigma}^2$ ,  $\hat{\sigma}$ , que se denomina **error estándar de la regresión**, como medida de la bondad del ajuste



# Medidas de bondad del ajuste

## El coeficiente de determinación

- Al igual que en el modelo de regresión simple, el  $R^2$  o **coeficiente de determinación**, se define como

$$R^2 = \frac{\sum_i \hat{y}_i^2}{\sum_i y_i^2} = 1 - \frac{\sum_i \hat{\varepsilon}_i^2}{\sum_i y_i^2}, \quad 0 \leq R^2 \leq 1$$

donde  $y_i = Y_i - \bar{Y}$ ,  $\hat{y}_i = \hat{Y}_i - \bar{Y}$ ,  $\hat{\varepsilon}_i = Y_i - \hat{Y}_i$ .

(la segunda igualdad es cierta siempre que el modelo tenga término constante)

- La interpretación del  $R^2$  es similar a la del modelo de regresión lineal simple. se interpreta como la proporción de la variación muestral de  $Y$  explicada por el modelo. (Véase Goldberger, pp. 82 y 83).



# Medidas de bondad del ajuste

## El coeficiente de determinación

- El  $R^2$  puede ser útil para comparar distintos modelos para la misma variable dependiente  $Y$ .
- El  $R^2$  aumenta siempre de valor al aumentar de número de regresores, sean éstos relevantes o no.
- Para eliminar este problema, se define el  $\bar{R}^2$ , también llamado  $R^2$  **corregido** ó  $R^2$  **ajustado de grados de libertad**,

$$\bar{R}^2 = 1 - \left[ (1 - R^2) \frac{n - 1}{n - K - 1} \right] = 1 - \frac{\sum_i \hat{\varepsilon}_i^2 / (n - K - 1)}{\sum_i y_i^2 / (n - 1)}.$$

- En cualquier caso, para tamaños muestrales grandes  $\bar{R}^2 \simeq R^2$ .



# Interpretación de los parámetros del modelo de regresión lineal

Capítulos 7 (7.5) y 13 (13.2) de Goldberger

Capítulos 2 (2.4), 3 (3.1) y 6 (6.2) de Wooldridge

- Hasta ahora nos hemos centrado en relaciones lineales (tanto en parámetros como en variables) entre la variable dependiente y las variables explicativas.
- Sin embargo, en economía muchas relaciones no son lineales.
- Es fácil incorporar relaciones no lineales en el análisis lineal de regresión (manteniendo la linealidad en parámetros) definiendo adecuadamente la variable dependiente y las explicativas.
- Muy importante: Con carácter general, cuando decimos que el modelo de regresión es lineal, queremos decir que es **lineal en los parámetros**, pudiendo ser no lineal en las variables.
- Con frecuencia, el modelo se expresa en términos de **transformaciones no lineales de las variables originales**.



# Interpretación de los parámetros del modelo de regresión lineal

- Un concepto muy importante en economía es el concepto de **elasticidad**, que es la variación porcentual que experimenta una variable ( $Y$ ) en respuesta a la variación porcentual de otra ( $X$ ).
  - En la mayoría de las especificaciones, la elasticidad no es constante, dependiendo de los valores concretos de la variable explicativas ( $X$ ) y la variable respuesta ( $Y$ ).

Las transformaciones que se apliquen a las variables afectan a la expresión que adopta la elasticidad.
- Vamos a contemplar los ejemplos más frecuentes en los trabajos aplicados.
- Por simplicidad, ilustraremos las especificaciones con una o dos variables explicativas.
- Utilizaremos el modelo lineal en parámetros y en variables como referencia.





# Interpretación. Especificaciones más usuales

## Modelo lineal en variables

- El modelo considerado es simplemente:

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

donde  $E(\varepsilon|X) = 0 \Rightarrow E(Y|X) = \beta_0 + \beta_1 X$ .

- Interpretación de  $\beta_1$ :

$$\beta_1 = \frac{\Delta E(Y|X)}{\Delta X} \Rightarrow \text{Si } X \text{ varía 1 unidad, } Y \text{ varía en promedio } \beta_1 \text{ unidades de } Y.$$

- Elasticidad de  $E(Y|X)$  con respecto a  $X$ :

$$\frac{E[(\Delta Y/Y)|X]}{\Delta X/X} = \beta_1 \frac{X}{E(Y|X)}$$



# Interpretación. Especificaciones más usuales

## Modelo lineal en variables (cont.)

- Nótese que la elasticidad depende de los valores concretos de  $X$  y de  $Y$ , y por lo tanto no es constante.
  - Es habitual aproximar elasticidades para individuos concretos (usando sus valores observados de  $X$ ,  $Y$ ) como

$$\beta_1 \frac{X}{Y}.$$

- En otras ocasiones, se evalúan las elasticidades para los valores medios de  $X$  e  $Y$

$$\beta_1 \frac{E(X)}{E(Y)}.$$



# Interpretación. Especificaciones más usuales

Modelos semilogarítmicos: *logaritmo en la variable exógena*

- En algunas situaciones queremos modelizar que variaciones en términos porcentuales en  $X$  producen variaciones constantes en términos absolutos en  $Y$ .
- El modelo considerado sería:

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

donde  $E(\varepsilon|X) = 0 \Rightarrow E(Y|X) = \beta_0 + \beta_1 \ln X$ .

- Interpretación de  $\beta_1$ :

$$\beta_1 = \frac{\Delta E(Y|X)}{\Delta \ln X} \simeq \frac{\Delta E(Y|X)}{\Delta X/X}$$

(nótese que si  $h(X) = \ln X$ , como  $h'(X) = \frac{dh(X)}{dX} = \frac{1}{X}$ , entonces diferenciando tenemos que  $dh(X) = d \ln X \equiv \frac{dX}{X}$ ).



# Interpretación. Especificaciones más usuales

Modelos semilogarítmicos: *logaritmo en la variable exógena* (cont.)

- $\beta_1$  es una **semielasticidad**.
- La elasticidad de  $E(Y|X)$  con respecto a  $X$  es igual a

$$\frac{\beta_1}{E(Y|X)},$$

que depende por tanto del valor concreto que tome  $E(Y|X)$ .



# Interpretación. Especificaciones más usuales

Modelos semilogarítmicos: *logaritmo en la variable exógena* (cont.)

- En todo caso, es habitual aproximar elasticidades para individuos concretos (usando sus valores de  $X$ ,  $Y$ ) como

$$\frac{\beta_1}{Y}$$

- Multiplicando y dividiendo por 100 para expresar la variación de  $X$  en **términos porcentuales**:

$$\beta_1/100 \simeq \frac{\Delta E(Y|X)}{100 \times \Delta X/X}$$

$\Rightarrow$  Si  $X$  varía en un 1%,  $Y$  varía en promedio en  $\beta_1/100$  unidades de  $Y$ .



# Interpretación. Especificaciones más usuales

Modelos semilogarítmicos: *logaritmo en la variable exógena* (cont.)

- **Ejemplo:** Sean  $Y =$  Consumo (en euros) y  $X =$  Renta.  
Definimos la Propensión Marginal a Consumir (PMC) como  $dY/dX$ .

## Modelo 1

---

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

$$\beta_1^* = \frac{\Delta E(Y|X)}{\Delta X}$$

---

Si la renta  $\uparrow$  1 unidad, el consumo  
 $\uparrow$  en media en  $\beta_1^*$  euros

## Modelo 2

---

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

$$\frac{\beta_1}{100} \simeq \frac{\Delta E(Y|X)}{100 \times \Delta X / X}$$

---

Si la renta  $\uparrow$  1%, el consumo  
 $\uparrow$  en media en  $\beta_1/100$  euros



# Interpretación. Especificaciones más usuales

Modelos semilogarítmicos: *logaritmo en la variable exógena* (cont.)

- La Propensión Marginal a Consumir  $dY/dX$  es:
  - $\beta_1^*$  (constante), en el Modelo 1.
  - es  $\beta_1/X$  (decreciente con la renta), en el Modelo 2.



# Interpretación. Especificaciones más usuales

Modelos semilogarítmicos: *logaritmo en la variable endógena*

- En algunas situaciones, queremos modelizar que variaciones en términos absolutos en  $X$  producen variaciones constantes en términos porcentuales en  $Y$ .
- El modelo considerado sería:

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

donde  $E(\varepsilon|X) = 0 \Rightarrow E(\ln Y|X) = \beta_0 + \beta_1 X$ .

- Este modelo se expresaría en términos de las variables originales como:

$$Y = \exp(\beta_0 + \beta_1 X + \varepsilon)$$





# Interpretación. Especificaciones más usuales

Modelos semilogarítmicos: *logaritmo en la variable endógena* (cont.)

- Interpretación de  $\beta_1$ :

$$\beta_1 = \frac{\Delta E(\ln Y|X)}{\Delta X} \simeq \frac{E[(\Delta Y/Y) | X]}{\Delta X}$$

- Si multiplicamos por 100 para expresar la variación de  $Y$  en términos porcentuales, tendremos que

$$\beta_1 \times 100 \simeq \frac{E[(100 \times \Delta Y/Y) | X]}{\Delta X}$$

$\Rightarrow$  Cuando  $X$  varía en un 1 unidad,  $Y$  varía en promedio en un  $(\beta_1 \times 100)$  %.



# Interpretación. Especificaciones más usuales

Modelos semilogarítmicos: *logaritmo en la variable endógena* (cont.)

- $\beta_1$  es una **semielasticidad**.
- La elasticidad de  $E(Y|X)$  con respecto a  $X$  es igual a  $\beta_1 X$  (y depende por tanto de los valores concretos que tome  $X$ ).
- Esta especificación es de gran utilidad para describir curvas de crecimiento exponencial.
- En particular, supongamos que  $X = t$  (tiempo). Entonces,  
$$Y = \exp(\beta_0 + \beta_1 t + \varepsilon)$$
 y como  $\beta_1 = \frac{\Delta E(\ln Y|X)}{\Delta t}$ ,  
 $\beta_1$  recoge la tasa de crecimiento medio de  $Y$  a lo largo del tiempo.



# Interpretación. Especificaciones más usuales

Modelos semilogarítmicos: *logaritmo en la variable endógena* (cont.)

- **Ejemplo:** Sean  $Y =$  Salario-hora (euros) y  $X =$  Educación (años).

## Modelo 1

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

$$\beta_1^* = \frac{\Delta E(Y|X)}{\Delta X}$$

Si la educ.  $\uparrow$  1 unidad, el salario  
 $\uparrow$  en media en  $\beta_1^*$  euros

## Modelo 2

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

$$\beta_1 \times 100 \simeq \frac{E[(100 \times \Delta Y / Y) | X]}{\Delta X}$$

Si la educ.  $\uparrow$  1 ud., el consumo  
 $\uparrow$  en media en  $(\beta_1 \times 100) \%$

- El incremento medio del salario-hora por año adicional de educación es:
  - $\beta_1^*$  euros en el Modelo 1 (constante, no depende del nivel de educación considerado).
  - $(\beta_1 \times Y)$  euros en el Modelo 2 (no es constante: depende del nivel salarial, que a su vez es creciente con la educación).



# Interpretación. Especificaciones más usuales

## Modelo doble logarítmico

- En algunas situaciones queremos modelizar que variaciones % en  $X$  producen variaciones % constantes en  $Y \Rightarrow$  **Elasticidad constante**.
- De gran utilidad en estudios de demanda, producción, costes, etc..
- El modelo considerado sería:

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

donde  $E(\varepsilon|X) = 0 \Rightarrow E(\ln Y|X) = \beta_0 + \beta_1 \ln X$ .

- Interpretación de  $\beta_1$ :

$$\beta_1 = \frac{\Delta E(\ln Y|X)}{\Delta \ln X} \simeq \frac{E[(\Delta Y/Y) | X]}{\Delta X/X} \Rightarrow \text{Cuando } X \text{ varía en un } 1\%, \text{ } Y \text{ varía en promedio un } \beta_1\%.$$

( $\beta_1$  es una elasticidad)



# Interpretación de los parámetros del modelo de regresión lineal

Modelo doble logarítmico (cont.)

- **Ejemplo:** Sean  $Y =$  Producción,  $X_1 =$  Input 1 (Trabajo) y  $X_2 =$  Input 2 (Capital).

$$Y = \beta_0^* + \beta_1^* X_1 + \beta_2^* X_2 + \varepsilon^* \quad \ln Y = \beta_0 + \beta_1 \ln X_1 + \beta_2 \ln X_2 + \varepsilon$$

$$\beta_j^* = \frac{\Delta E(Y|X_1, X_2)}{\Delta X_j} \quad \beta_j \simeq \frac{E[(\Delta Y/Y) | X_1, X_2]}{\Delta X_j / X_j}$$

Si el input  $j \uparrow 1$  unidad, permaneciendo el otro input constante la prod.  $\uparrow$  en media en:

$\beta_j^*$ ud. de producto	$\beta_j$ %
-----------------------------	-------------

elasticidad no constante:                      elasticidad constante:

$\frac{\Delta Y/Y}{\Delta X_j/X_j} = \beta_j^* \frac{X_j}{Y}$	$\beta_j$
---	-----------

- El Modelo 2 tiene la siguiente representación en términos de las variables originales:

$$Y = B_0 X_1^{\beta_1} X_2^{\beta_2} \exp(\varepsilon) \quad (\text{Cobb-Douglas})$$



# Interpretación. Especificaciones más usuales

## Modelo con términos cuadráticos

- En algunas situaciones, queremos modelizar la relación entre  $X$  e  $Y$  considerando la existencia de efectos marginales crecientes o decrecientes.
- Es útil en la especificación de tecnologías o de funciones de gasto o de costes, etc.
- El modelo considerado sería:

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \varepsilon$$

donde  $E(\varepsilon|X) = 0 \Rightarrow E(Y|X) = \beta_0 + \beta_1 X + \beta_2 X^2$ .



- En este contexto,

$$\frac{\Delta E(Y|X)}{\Delta X} = \beta_1 + 2\beta_2 X,$$

es decir: Cuando  $X$  varía en 1 unidad,  $Y$  varía en media en  $(\beta_1 + 2\beta_2 X)$  unidades de  $Y$ ..

- Nótese que  $\beta_1$  y  $\beta_2$  **no tienen interpretación por separado**.
  - Dependiendo del signo de los efectos marginales serán crecientes ( $\beta_2 > 0$ ) o decrecientes ( $\beta_2 < 0$ ).
  - Existe un valor crítico de  $X$  en el que el efecto de  $X$  sobre  $E(Y|X)$  cambia de signo. Dicho punto es  $X^* = -\beta_1/2\beta_2$



# Interpretación. Especificaciones más usuales

## Modelo con términos cuadráticos (cont.)

- **Ejemplo:** Sean  $Y =$  Salario-hora (euros),  $X_1 =$  Educación (años) y  $X_2 =$  Experiencia (años).

### Modelo 1

$$\ln Y = \beta_0^* + \beta_1^* X_1 + \beta_2^* X_2 + \varepsilon^*$$

$$\beta_2^* = \frac{\Delta E((\Delta Y/Y) | X_1, X_2)}{\Delta X_2}$$

Si la experiencia  $\uparrow$  1 año, permaneciendo constante la educación, el salario-hora  $\uparrow$  en media en:

$$(\beta_2^* \times 100) \%$$

El rendimiento de 1 año adicional de experiencia es:  
constante

### Modelo 2

$$\ln Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_2^2 + \varepsilon$$

$$(\beta_2 + 2\beta_3 X_2) \simeq \frac{E[(\Delta Y/Y) | X_1, X_2]}{\Delta X_2}$$

$$100 \times (\beta_2 + 2\beta_3 X_2) \%$$

no constante (depende de Experiencia)





# Interpretación. Especificaciones más usuales

Otros modelos: Modelo recíproco

- El modelo considerado sería:

$$Y = \beta_0 + \beta_1 \frac{1}{X} + \varepsilon,$$

donde  $E(\varepsilon|X) = 0 \Rightarrow E(Y|X) = \beta_0 + \beta_1 \frac{1}{X}$ .

- Permite una formulación con curvatura hiperbólica.
- Se emplea, por ejemplo, para la curva de Phillips (inflación - desempleo).
- Al variar  $X$  en una unidad,  $Y$  varía en media en  $-\beta_1 \frac{1}{X^2}$  unidades.



# Interpretación. Especificaciones más usuales

Otros modelos: Modelos con interacciones

- El modelo considerado sería:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_1 X_2 + \varepsilon,$$

donde:

$$E(\varepsilon|X_1, X_2) = 0 \Rightarrow E(Y|X_1, X_2) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_1 X_2.$$

- Al variar (por ejemplo)  $X_1$  en una unidad,  $Y$  varía en media en  $\beta_1 + \beta_3 X_2$  unidades.
- Nótese que **los parámetros no tienen interpretación por separado.**



- Las características de los modelos anteriores pueden combinarse, de manera que podemos tener modelos logarítmicos o semilogarítmicos con interacciones, potencias, etc.
- **Ejemplo:** Función de producción translogarítmica:
- Sean  $Y =$  Producción,  $X_1 =$  Input 1 (Trabajo) y  $X_2 =$  Input 2 (Capital).

$$\ln Y = \beta_0 + \beta_1 \ln X_1 + \beta_2 \ln X_2 + \beta_3 (\ln X_1)^2 + \beta_4 (\ln X_2)^2 + \beta_5 (\ln X_1) (\ln X_2) + \varepsilon$$



# Interpretación. Especificaciones más usuales

## Comentarios finales (cont.)

- En este modelo, las elasticidades del output con respecto al trabajo o al capital no son constantes, a pesar de estar expresadas las variables en logaritmos. En particular:

$$\frac{E [(\Delta Y / Y) \mid X_1, X_2]}{\Delta X_1 / X_1} \simeq \beta_1 + 2\beta_3 \ln X_1 + \beta_5 \ln X_2,$$

que depende de los logaritmos de los inputs.

- La especificación translogarítmica se utiliza también para representar funciones de gasto y funciones de costes.



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

Goldberger: Capítulos 7, 10 (10.3), 11 y 12 (12.5 y 12.6).

Wooldridge: Capítulos 4 y 5 (5.2).

- Un **contraste de hipótesis** es una técnica de inferencia estadística que permite evaluar si la información que proporcionan los datos (la muestra) avala o no una determinada **conjetura** o **hipótesis** sobre la población objeto de estudio.
- Las hipótesis estadísticas pueden ser:
  - **No paramétricas**: sobre propiedades de la distribución poblacional (observaciones independientes, normalidad, simetría, etc.)
  - **Paramétricas**: condiciones o restricciones sobre los valores de los parámetros poblacionales.



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

- La hipótesis a contrastar se denomina **hipótesis nula** ( $H_0$ ).
- La negación o el complementario de la hipótesis nula se denomina **hipótesis alternativa** ( $H_1$ )
- El enfoque clásico de contraste, basado en Neyman-Pearson, consiste en dividir el espacio muestral, dada  $H_0$ , en dos regiones, una de región de aceptación y otra región de rechazo (o región crítica). Si los datos observados caen en la región de rechazo, se rechazará la hipótesis nula.



# Contraste de hipótesis: Estrategia clásica

- 1 Definir la hipótesis nula ( $H_0$ ) y la hipótesis alternativa ( $H_1$ ).
- 2 Determinar un **estadístico de contraste**, que mide la discrepancia entre la información muestral y la hipótesis  $H_0$ .
- 3 Determinar qué discrepancias se consideran grandes (y por tanto, qué valores del estadístico se consideran no plausibles bajo  $H_0$ ), es decir, determinar la región crítica o de rechazo. Dicha región viene dada por un **valor crítico**, dada la distribución del estadístico.
- 4 Dada la muestra, calcular el valor muestral del estadístico y ver si se encuentra en la región de aceptación o de rechazo.



- Dicho estadístico de contraste:
  - es función de  $H_0$  y de los datos muestrales, con lo que es una variable aleatoria (que tomará valores distintos para cada muestra)
  - debe tener una distribución conocida (exacta o aproximada) bajo  $H_0$  (cuando  $H_0$  sea cierta).
    - Si la discrepancia entre la información muestral y  $H_0$  es notable, el valor del estadístico estará dentro de un rango de valores poco probable cuando  $H_0$  es cierta, lo que sería evidencia contra  $H_0$ .
    - Si la discrepancia entre la información muestral y  $H_0$  es pequeña, el valor del estadístico estará dentro de un rango de valores muy probable cuando  $H_0$  es cierta, lo que sería evidencia a favor de  $H_0$ .





# Contraste de hipótesis: Estrategia clásica

- Puesto que la muestra en que se basa el contraste es aleatoria, el estadístico de contraste (que es una función de la muestra) es también una variable aleatoria.
  - Por tanto, el estadístico de contraste puede conducir a conclusiones diferentes para distintas muestras.
  - Una vez realizado el contraste, habremos optado bien por  $H_0$ , bien por  $H_1$ , y estaremos en alguna de las cuatro situaciones siguientes:

		Realidad	
		$H_0$ cierta	$H_0$ falsa
Conclusión del contraste	Aceptamos $H_0$	✓	Error tipo II
	Rechazamos $H_0$	Error tipo I	✓

- Se define **tamaño del contraste** o **nivel de significación** =  $\alpha = \Pr(\text{error de tipo I}) = \Pr(\text{Rechazar } H_0 | H_0)$



# Contraste de hipótesis: Estrategia clásica

- En la práctica, no es posible minimizar la probabilidad de ambos tipos de error para un tamaño muestral dado
  - La única forma de reducir la probabilidad de ambos errores es incrementando el tamaño muestral
- El procedimiento clásico consiste en:
  - fijar  $\alpha$  (tamaño o nivel de significación del contraste), es decir, establecer la probabilidad máxima de rechazar  $H_0$  cuando es cierta.
    - Se establece un valor tan pequeño como se desee (10% o menor).
  - minimizar  $\Pr(\text{error de tipo II}) = \Pr(\text{No rechazar } H_0 | H_1)$  o, de forma equivalente, maximizar

$$1 - \Pr(\text{error de tipo II}) = \text{potencia del contraste.}$$

Como la potencia está definida bajo la hipótesis alternativa, su valor dependerá del verdadero valor del parámetro (que es desconocido)



- Un **contraste es consistente** si  $\lim_{n \rightarrow \infty} [1 - \Pr(\text{error de tipo II})] = 1$ .
- Por tanto, dada  $H_0$ :
  - se define el estadístico de contraste  $C$ ,
  - se determina la región crítica (a partir de la distribución de  $C$  bajo  $H_0$ ) para un nivel de significación  $\alpha$  prefijado,
  - se evalúa el estadístico para los datos disponibles,  $\hat{C}$ .
  - Si el valor del estadístico  $\hat{C}$  cae en la región crítica, se rechaza  $H_0$  al nivel de significación  $100\alpha\%$ ; en caso contrario, no se rechaza  $H_0$ .



# Contraste de hipótesis: Estrategia clásica

- Como procedimiento alternativo, podemos utilizar el **nivel crítico** o **p-valor**, que se define como

$$\mathbf{p\text{-valor}} = p = \Pr \left( \hat{C} \in \{\text{región crítica}\} \mid H_0 \right)$$

es decir, el **p-valor** es la probabilidad de obtener una discrepancia mayor o igual que la obtenida cuando  $H_0$  es cierta (dada la distribución de  $H_0$ ).

- Cuanto menor sea el **p-valor**, menos probable es que la distribución obtenida para el estadístico bajo  $H_0$  sea correcta, y por tanto es menos probable que estemos bajo  $H_0$ .
- El **p-valor** no proporciona una decisión entre  $H_0$  y  $H_1$ : nos indica cómo de probable es que estemos bajo  $H_0$ .
- Una vez calculado el **p-valor**  $p$  para el valor muestral del estadístico, sabemos que rechazaríamos  $H_0$  a cualquier nivel de significación igual o mayor que  $p$ .



# Ejemplo: Contraste sobre la media poblacional

- Dada una variable aleatoria  $Y$ , queremos contrastar si  $E(Y) \equiv \mu = \mu_0$ , donde  $\mu_0$  es cierto valor.
- La hipótesis nula es  $H_0 : \mu = \mu_0$ . La hipótesis alternativa es  $H_1 : \mu \neq \mu_0$ .
- Para evaluar esta hipótesis, disponemos de una muestra de tamaño  $n$ ,  $\{Y_i\}_{i=1}^n$ , donde las  $Y_i$ 's son independientes, con la que podemos estimar la media muestral de  $Y$ :

$$\hat{\mu} \equiv \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i$$



## Ejemplo: Contraste sobre la media poblacional (ii)

- donde la esperanza y la varianza de  $\bar{Y}$  son:

$$E(\bar{Y}) = E\left(\frac{1}{n} \sum_{i=1}^n Y_i\right) = \frac{1}{n} \sum_{i=1}^n E(Y_i) = \frac{1}{n} n\mu = \mu,$$

$$V(\bar{Y}) = V\left(\frac{1}{n} \sum_{i=1}^n Y_i\right) = \frac{1}{n^2} \sum_{i=1}^n V(Y_i) = \frac{1}{n^2} n\sigma^2 = \frac{\sigma^2}{n}.$$



## Ejemplo: Contraste sobre la media poblacional (iii)

- Supongamos que  $Y \sim N(\mu, \sigma^2)$ , donde  $\sigma^2$  es conocida.
  - Si  $Y$  tiene una distribución normal, las observaciones muestrales de  $Y$ ,  $Y_i$ , que son realizaciones de  $Y$ , seguirán la misma distribución.
  - Como  $\bar{Y}$  es una combinación lineal de variables aleatorias normales, tendremos que  $\bar{Y}$  tendrá también una distribución normal,

$$\bar{Y} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

- En particular, bajo  $H_0 : \mu = \mu_0$ , tenemos que  $\bar{Y} \sim N\left(\mu_0, \frac{\sigma^2}{n}\right)$ .
- Podemos definir el estadístico  $\hat{C} = \frac{\bar{Y} - \mu_0}{\sigma/\sqrt{n}}$ . Este estadístico se distribuye bajo  $H_0$  como

$$\hat{C} = \frac{\bar{Y} - \mu_0}{\sigma/\sqrt{n}} = \sqrt{n} \frac{\bar{Y} - \mu_0}{\sigma} \sim N(0, 1)$$



## Ejemplo: Contraste sobre la media poblacional (iv)

- Por tanto, la distribución de nuestro estadístico bajo  $H_0$  es una normal estándar.
- El contraste consiste en evaluar si la discrepancia, medida por el estadístico, es estadísticamente grande en valor absoluto. (nos interesa el tamaño, no la dirección, de dicha discrepancia).
- Si aplicamos el procedimiento clásico, determinamos un nivel de significación  $\alpha$ .
- En este caso, se trata de un contraste de dos colas, con probabilidades acumuladas respectivas iguales a  $\frac{\alpha}{2}$ , en el que la región de aceptación corresponde a discrepancias extremas, sean positivas o negativas.

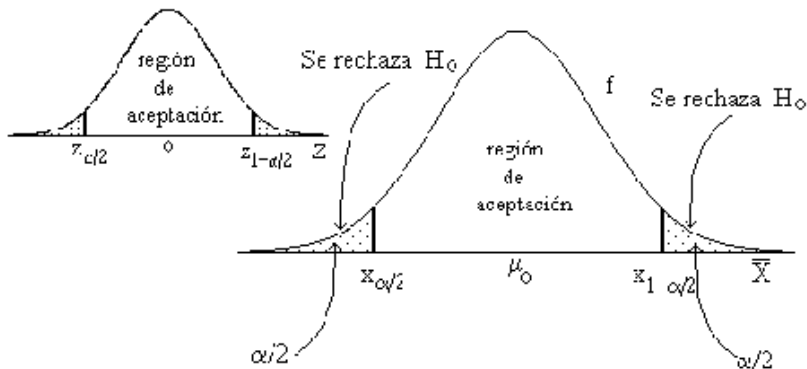




## Ejemplo: Contraste sobre la media poblacional ( $v$ )

- Denotando  $Z_p$  como el valor de la  $N(0, 1)$  que deja una probabilidad acumulada de  $p$  a su izquierda, la región crítica es

$$\left\{ \hat{C} : \hat{C} < Z_{\frac{\alpha}{2}} \right\} \cup \left\{ \hat{C} : \hat{C} > Z_{1-\frac{\alpha}{2}} \right\} = \left\{ \hat{C} : |\hat{C}| > Z_{1-\frac{\alpha}{2}} \right\}$$



## Ejemplo: Contraste sobre la media poblacional (vi)

- Si  $Y \sim N(\mu, \sigma^2)$ , pero  $\sigma^2$  es desconocida, tendremos que estimar  $\sigma^2$ .
  - En ese caso, el estadístico factible es

$$\hat{C} = \sqrt{n} \frac{\bar{Y} - \mu_0}{\hat{\sigma}} \sim t_{n-1}$$

donde  $\hat{\sigma} = \sqrt{\hat{\sigma}^2}$ , siendo  $\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2$  un estimador consistente de  $\sigma^2$ .

- La distribución de este estadístico es una  $t$  de Student con  $n - 1$  grados de libertad.
- Si  $n$  es grande, el resultado del contraste será similar, tanto si suponemos que  $\sigma^2$  es conocida como si no, porque la distribución  $t$  de Student se aproxima a la normal estándar a medida que  $n$  aumenta.



## Ejemplo: Contraste sobre la media poblacional (vii)

- Si desconocemos tanto la distribución de  $Y$  como  $\sigma^2$ , podemos seguir utilizando el estadístico

$$\hat{C} = \sqrt{n} \frac{\bar{Y} - \mu_0}{\hat{\sigma}}$$

- PERO ahora no tendremos una distribución conocida (exacta) para el estadístico  $\hat{C}$ .
- Sin embargo, teniendo en cuenta que las observaciones de la muestra  $\{Y_i\}_{i=1}^n$  son independientes y suponiendo que tienen idéntica distribución, podemos aplicar el Teorema Central del Límite, por el que la distribución asintótica del estadístico es una normal estándar

$$\hat{C} = \sqrt{n} \frac{\bar{Y} - \mu_0}{\hat{\sigma}} \sim N(0, 1),$$

de manera que podemos utilizar la normal para realizar el contraste de forma aproximada.



- En la práctica:
  - No conocemos habitualmente la distribución de la(s) variable(s) consideradas.
  - Si el tamaño muestral es grande, la aproximación asintótica proporciona conclusiones similares.



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Distribuciones muestrales de los estimadores MCO

- Vamos a centrarnos en el contraste de hipótesis caracterizadas por restricciones lineales sobre los parámetros  $\beta_0, \beta_1, \dots, \beta_K$ .
- Para ello, construiremos estadísticos de contraste, de los que derivaremos sus distribuciones.
- Hemos derivado los estimadores MCO de los parámetros del modelo de regresión lineal múltiple y sus propiedades, a partir de los supuestos **1.** a **4.**
- Sin embargo, para hacer inferencia debemos caracterizar la distribución muestral de los estimadores MCO, para poder construir estadísticos de contraste de los que podamos derivar sus distribuciones.



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Distribuciones muestrales de los estimadores MCO

- Para poder derivar distribuciones exactas, necesitaríamos suponer que:

$$Y_i \mid X_{1i}, \dots, X_{Ki} \sim N(\beta_0 + \beta_1 X_{1i} + \dots + \beta_K X_{Ki}, \sigma^2),$$
$$\Leftrightarrow \varepsilon_i \mid X_{1i}, \dots, X_{Ki} \sim N(0, \sigma^2)$$

en cuyo caso es posible demostrar que los estimadores MCO  $\hat{\beta}_j$  ( $j = 1, \dots, K$ ) siguen una distribución  $N(\beta_j, V(\hat{\beta}_j))$ .

- Sin embargo, este supuesto no es en general verificable, y es difícil que se cumpla.
  - En ese caso, la distribución de los estimadores  $\hat{\beta}_j$  será desconocida.



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Distribuciones muestrales de los estimadores MCO

- **Habitualmente, trabajaremos bajo el supuesto de que desconocemos la distribución de  $Y$  condicional a las  $X$ 's, de manera que nuestra inferencia se basará en la aproximación asintótica.**
- Por ello, trabajaremos con la distribución asintótica de los estimadores  $\hat{\beta}_j$  ( $j = 1, \dots, K$ ).
- Puede probarse que

$$\hat{\beta}_j \sim N(\beta_j, V(\hat{\beta}_j))$$

y por tanto

$$\frac{\hat{\beta}_j - \beta_j}{\sqrt{V(\hat{\beta}_j)}} \sim N(0, 1)$$



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Distribuciones muestrales de los estimadores MCO

- Si sustituimos  $V(\hat{\beta}_j)$  por un estimador consistente,  $V(\hat{\beta}_j) = \frac{\hat{\sigma}^2}{nS_j^2(1-R_j^2)}$ , este resultado se mantiene

$$\frac{\hat{\beta}_j - \beta_j}{\sqrt{\hat{V}(\hat{\beta}_j)}} \sim N(0, 1)$$





# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes sobre el valor de un parámetro

- Sea la hipótesis nula  $H_0 : \beta_j = \beta_j^0$  vs. la hipótesis alternativa,  $H_1 : \beta_j \neq \beta_j^0$ .
- Para evaluar esta hipótesis, construimos el estadístico  $t$ ,

$$t = \frac{\hat{\beta}_j - \beta_j^0}{\sqrt{\hat{V}(\hat{\beta}_j)}} \equiv \frac{\hat{\beta}_j - \beta_j^0}{s_{\hat{\beta}_j}}$$

donde  $s_{\hat{\beta}_j} = \sqrt{\hat{V}(\hat{\beta}_j)}$  se conoce como error estándar de  $\hat{\beta}_j$ .

- Dicho estadístico se distribuye aproximadamente bajo  $H_0$  como:

$$t = \frac{\hat{\beta}_j - \beta_j^0}{s_{\hat{\beta}_j}} \sim N(0, 1)$$



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes sobre el valor de un parámetro

- La mayoría de los programas econométricos presentan el coeficiente estimado seguido de su error estándar, del estadístico  $t$  y del p-valor asociado al valor del estadístico  $t$ .
  - Habitualmente, dichos programas calculan el p-valor en base a la distribución  $t$  de Student con  $n - K - 1$  grados de libertad.
  - Si  $n$  es moderadamente grande, utilizar la distribución aproximada o la  $t$  de Student no tiene consecuencias en la inferencia.  
Por ejemplo, si en un contraste de dos colas consideramos el valor crítico para un nivel de significación  $\alpha$ , que determina una región crítica  $|t| > t_{1-\frac{\alpha}{2}}$ , para  $n - K - 1 = 120$ :
    - para  $\alpha = 0.05$ , dicho valor crítico es 1.98 si consideramos la  $t$  de Student y 1.96 si consideramos la  $N(0, 1)$ .
    - para  $\alpha = 0.10$ , dicho valor crítico es 1.658 si consideramos la  $t$  de Student y 1.645 si consideramos la  $N(0, 1)$ .



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes sobre el valor de un parámetro

- Por tanto, podemos tomar los p-valores que aparecen en las tablas de resultados de los programas econométricos siempre que  $n$  no sea muy pequeño.
- Por supuesto, a partir de estos resultados pueden también construirse intervalos de confianza aproximados
- **Ejemplo:** Demanda de dinero y actividad económica (Goldberger, p. 107).  
Utilizando los datos para EE.UU. del archivo TIM1.GDT, hemos estimado la siguiente regresión lineal:



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

Contrastes sobre el valor de un parámetro

- Model 1: OLS, using observations 1959–1996 ( $T = 38$ )  
Dependent variable:  $Y$

	Coefficient	Std. Error	$t$ -ratio	p-value
const	2.3296	0.2054	11.3397	0.0000
X1	0.5573	0.0264	21.1227	0.0000
X2	-0.2032	0.0210	-9.6719	0.0000

Mean dependent var	6.628638	S.D. dependent var	0.172887
Sum squared resid	0.080411	S.E. of regression	0.047932
$R^2$	0.927291	Adjusted $R^2$	0.923137
$F(2, 35)$	223.1866	P-value( $F$ )	1.20e-20



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes sobre el valor de un parámetro

donde:

- $Y = \ln(100 \times V4/V3) =$  logaritmo de la cantidad real de dinero (M1)
- $X_1 = \ln(V2) =$  logaritmo del PIB real
- $X_2 = \ln(V6) =$  logaritmo del tipo de interés de las Letras del Tesoro
- **Interpretación:**
  - $\hat{\beta}_1$ : estimación de la elasticidad de la demanda de dinero con respecto a la producción (manteniendo el tipo de interés constante).  
Si el PIB aumenta en un 1% (y el tipo de interés no varía) se estima que la demanda de dinero aumenta en promedio un 0.6%.
  - $\hat{\beta}_2$ : estimación de la elasticidad de la demanda de dinero con respecto al tipo de interés (manteniendo la producción constante).  
Si el tipo de interés aumenta en un 1% (y el PIB no varía) se estima que la demanda de dinero cae en promedio un 0.2%.



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes sobre el valor de un parámetro

- Queremos contrastar dos hipótesis:
  - Que la demanda de dinero es inelástica al tipo de interés.
  - Que la elasticidad de la demanda de dinero resp. a la producción es 1.
- $H_0 : \beta_2 = 0$  (la demanda de dinero es inelástica al tipo de interés) frente a  $H_1 : \beta_2 \neq 0$

Entonces, bajo  $H_0$ ,  $t = \frac{\hat{\beta}_2 - 0}{s_{\hat{\beta}_2}} \sim N(0, 1)$  y

$$|t| = \left| \frac{-0.2032}{0.021} \right| = 9.676 > Z^* = 1.96$$

- Nótese que, dado que  $|t| \simeq 9.7$ , el p-valor es prácticamente 0 (para un valor  $Z = 3.09$ , el p-valor en la tabla de la normal es  $0.001 = 0.1\%$ ).
  - $\Rightarrow$  se rechaza  $H_0$  al nivel de significación del 1%.
  - Intervalo de confianza al 95% para  $\beta_2$ :

$$\hat{\beta}_2 \pm s_{\hat{\beta}_2} \times 1.96 : \Rightarrow -0.2032 \pm 0.0210 \times 1.96 \Rightarrow [-0.244 ; 0.162]$$



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes sobre el valor de un parámetro

- $H_0 : \beta_1 = 1$  (elasticidad unitaria de la demanda de dinero con respecto a la producción)  
frente a  $H_1 : \beta_1 \neq 1$

Entonces, bajo  $H_0$ ,  $t = \frac{\hat{\beta}_1 - 1}{s_{\hat{\beta}_1}} \sim N(0, 1)$  y

$$|t| = \left| \frac{0.5573 - 1}{0.0264} \right| = 16.769 > Z^* = 1.96$$

- El p-valor asociado es prácticamente 0.
- $\Rightarrow$  se rechaza  $H_0$  al nivel de significación del 1%.
- Intervalo de confianza al 95% para  $\beta_1$ :

$$\hat{\beta}_1 \pm s_{\hat{\beta}_1} \times 1.96 : \Rightarrow 0.5573 \pm 0.0264 \times 1.96 \Rightarrow [0.505 ; 0.609]$$



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes sobre una hipótesis lineal

- Sea la hipótesis nula  $H_0 : \lambda_0\beta_0 + \lambda_1\beta_1 + \dots + \lambda_K\beta_K = \mu^0$ .
- Para evaluar esta hipótesis, construimos el estadístico  $t$ ,

$$\begin{aligned} t &= \frac{\lambda_0\hat{\beta}_0 + \lambda_1\hat{\beta}_1 + \dots + \lambda_K\hat{\beta}_K - \mu^0}{\sqrt{\hat{V}(\lambda_0\hat{\beta}_0 + \lambda_1\hat{\beta}_1 + \dots + \lambda_K\hat{\beta}_K)}} \\ &\equiv \frac{\lambda_0\hat{\beta}_0 + \lambda_1\hat{\beta}_1 + \dots + \lambda_K\hat{\beta}_K - \mu^0}{s_{\lambda_0\hat{\beta}_0 + \lambda_1\hat{\beta}_1 + \dots + \lambda_K\hat{\beta}_K}} \end{aligned}$$

- Empleando la aproximación asintótica tenemos que bajo  $H_0$ :

$$t = \frac{\lambda_0\hat{\beta}_0 + \lambda_1\hat{\beta}_1 + \dots + \lambda_K\hat{\beta}_K - \mu^0}{s_{\lambda_0\hat{\beta}_0 + \lambda_1\hat{\beta}_1 + \dots + \lambda_K\hat{\beta}_K}} \sim N(0, 1).$$





# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes sobre una hipótesis lineal

- **Ejemplo:** Tecnología de producción.

$$\hat{Y} = 2.37 + 0.632X_1 + 0.452X_2 \quad n = 31$$

$(0.257) \quad (0.219)$

$$s_{\hat{\beta}_1\hat{\beta}_2} = \hat{C}(\hat{\beta}_1, \hat{\beta}_2) = 0.055$$

donde

- $Y$  = logaritmo de la producción
- $X_1$  = logaritmo del trabajo
- $X_2$  = logaritmo del capital



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes sobre una hipótesis lineal

- **Interpretación:**

- $\hat{\beta}_1$ : estimación de la elasticidad de la producción respecto al trabajo (manteniendo el capital constante)  
Si el trabajo aumenta en un 1% (y el capital no varía) se estima que la producción aumenta en promedio en un 0.63%.
- $\hat{\beta}_2$ : estimación de la elasticidad de la producción respecto al capital (manteniendo el trabajo constante)  
Si el capital aumenta en un 1% (y el trabajo no varía) se estima que la producción aumenta en promedio en un 0.45%.



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes sobre una hipótesis lineal

- Consideremos la hipótesis nula  $H_0 : \beta_1 + \beta_2 = 1$  (Rendimientos constantes a escala) frente a la hipótesis alternativa  $H_1 : \beta_1 + \beta_2 \neq 1$ .
  - Bajo  $H_0$ :

$$t = \frac{\hat{\beta}_1 + \hat{\beta}_2 - 1}{s_{\hat{\beta}_1 + \hat{\beta}_2}} \sim N(0, 1).$$

donde  $s_{\hat{\beta}_1 + \hat{\beta}_2} = \sqrt{\widehat{V}(\hat{\beta}_1 + \hat{\beta}_2)} = \sqrt{\widehat{V}(\hat{\beta}_1) + \widehat{V}(\hat{\beta}_2) + 2\widehat{C}(\hat{\beta}_1, \hat{\beta}_2)}$ , y

$$|t| = \left| \frac{0.632 + 0.452 - 1}{\sqrt{(0.257)^2 + (0.219)^2 + 2 \times 0.055}} \right| = 0.177 < Z^* = 1.96$$

Por tanto, no se rechaza la hipótesis nula de rendimientos constantes a escala.



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes de varias restricciones lineales

- ¿Cómo se puede contrastar más de una hipótesis sobre los parámetros del modelo?
- Por ejemplo. ¿Cómo puedo contrastar  $q$  hipótesis lineales como las siguientes:

- $H_0 : \beta_1 = \beta_2 = \dots = \beta_K = 0$

- $H_0 : \beta_1 = 0$   
 $\beta_2 = 1$

- $H_0 : \beta_1 + \beta_3 = 0$   
 $\beta_2 = -1$   
 $\beta_4 - 2\beta_5 = 1$



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes de varias restricciones lineales

- **Conceptos previos:**

- Modelo “no restringido”: es aquel modelo sobre el que se desea efectuar un contraste de hipótesis (bajo  $H_1$ ).
- Modelo “restringido”: es aquel modelo en que se ha impuesto la hipótesis que se desea contrastar (bajo  $H_0$ ).
- **Ejemplo 1:**  $H_0 : \beta_1 = \beta_2 = 0$  vs.  $H_1 : \beta_1 \neq 0$  y/o  $\beta_2 \neq 0$ .

Modelo no restringido	Modelo restringido
$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \varepsilon$	$Y = \beta_0 + \varepsilon$



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes de varias restricciones lineales

- **Ejemplo 2:**  $H_0 : \beta_2 + 2\beta_1 = 1$  vs.  $H_1 : \beta_2 + 2\beta_1 \neq 1$

Modelo no restringido	Modelo restringido
$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \varepsilon$	$Y^* = \beta_0 + \beta_1 X^* + \varepsilon$ <p>donde: <math>Y^* = Y - X_2</math> <math>X^* = X_1 - 2X_2</math></p>

porque  $\beta_2 + 2\beta_1 = 1 \Rightarrow \beta_2 = 1 - 2\beta_1 \Rightarrow$   
 $Y = \beta_0 + \beta_1 X_1 + (1 - 2\beta_1) X_2 + \varepsilon \Rightarrow$   
 $(Y - X_2) = \beta_0 + \beta_1 (X_1 - 2X_2) + \varepsilon$



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes de varias restricciones lineales

- Definiciones:

	Modelo no restringido	Modelo restringido
Coefficientes de determinación:	$R_S^2$	$R_R^2$
Suma de cuadrados de los residuos:	$\sum_i \hat{\varepsilon}_{iS}^2 = SRS$	$\sum_i \hat{\varepsilon}_{iR}^2 = SRR$



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes de varias restricciones lineales

- Empleando la aproximación asintótica tenemos que bajo  $H_0$  [ $q$  hipótesis lineales],

$$W^0 = n \frac{SRR - SRS}{SRS} \sim \chi_q^2$$

o de modo equivalente (siempre que en el modelo restringido la variable dependiente sea idéntica a la del modelo sin restringir),

$$W^0 = n \frac{R_S^2 - R_R^2}{1 - R_S^2} \sim \chi_q^2$$

Nótese que utilizamos  $n$  en vez de  $(n - K - 1)$ , lo que para tamaños muestrales grandes no supone diferencias sustanciales.





# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contrastes de varias restricciones lineales

- La mayoría de los programas econométricos permiten realizar el contraste de forma automática si se escribe la hipótesis nula..
  - Habitualmente, dichos programas proporcionan el estadístico  $F$ , que supone normalidad condicional de las observaciones.
  - Dicho estadístico tendría la forma:

$$F = \frac{SRR - SRS}{SRS} \times \frac{n - K - 1}{q} \sim F_{q, n-K-1}$$

y se relaciona por tanto con el estadístico asintótico  $W^0$  como  $W^0 \simeq qF$ .

- De nuevo, si  $n$  es moderadamente grande, cuál de los dos se utilice no altera las conclusiones del contraste.
  - Pero nosotros aplicaremos contrastes asintóticos.
- Nótese que es fácil demostrar que  $(SRR - SRS) \geq 0$  y que  $(R_S^2 - R_R^2) \geq 0$ .
- Todos los casos vistos anteriormente son casos particulares de este



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contraste de significación conjunta o global

- Este contraste se conoce también como “contraste de regresión”.

- $H_0 : \beta_1 = \beta_2 = \dots = \beta_K = 0$

frente a

$$H_1 : \beta_j \neq 0 \text{ para algún } j = 1, \dots, K.$$

Modelo sin restringir

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_K X_K + \varepsilon$$

Modelo restringido

$$Y = \beta_0 + \varepsilon \Rightarrow R_R^2 = 0$$

- Empleando la aproximación asintótica tenemos que bajo  $H_0$ ,

$$W^0 = n \frac{R_S^2}{1 - R_S^2} \sim \chi_K^2$$



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contraste de significación conjunta o global

- Habitualmente, los programas econométricos proporcionan el estadístico  $F$  del contraste de regresión,

$$F = \frac{R_S^2}{1 - R_S^2} \times \frac{n - K - 1}{K} \sim F_{K, n-K-1}$$

que se relaciona con el estadístico asintótico  $W^0$  en la forma  $W^0 \simeq KF$  (para  $n$  moderadamente grande).

- De nuevo, utilizaremos el contraste asintótico.
- **Ejemplo:** Demanda de dinero y actividad económica (Goldberger, p. 107).

Utilizando los datos para EE.UU. del archivo TIM1.GDT, hemos estimado la siguiente regresión lineal:



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

Contraste de significación conjunta o global

- Model 1: OLS, using observations 1959–1996 ( $T = 38$ )  
Dependent variable:  $Y$

	Coefficient	Std. Error	$t$ -ratio	p-value
const	2.3296	0.2054	11.3397	0.0000
X1	0.5573	0.0264	21.1227	0.0000
X2	-0.2032	0.0210	-9.6719	0.0000

Mean dependent var	6.628638	S.D. dependent var	0.172887
Sum squared resid	0.080411	S.E. of regression	0.047932
$R^2$	0.927291	Adjusted $R^2$	0.923137
$F(2, 35)$	223.1866	P-value( $F$ )	$1.20e-20$



# Inferencia en el modelo de regresión lineal: Contraste de hipótesis

## Contraste de significación conjunta o global

donde:

- $Y = \ln(100 \times V4/V3) =$  logaritmo de la cantidad real de dinero (M1)
- $X_1 = \ln(V2) =$  logaritmo del PIB real
- $X_2 = \ln(V6) =$  logaritmo del tipo de interés de las Letras del Tesoro
- Consideramos la hipótesis nula  $H_0 : \beta_1 = \beta_2 = 0$  (la demanda de dinero es inelástica a la producción y a los tipos de interés) frente a la alternativa  $H_1 : \beta_1 \neq 0$  y/o  $\beta_2 \neq 0$ .
- El contraste asintótico es

$$W^0 = \frac{0.927}{1 - 0.927} \times 38 = 482.55 > \chi_2^2 = 5.99$$

- La salida de Gretl proporciona el estadístico  $F$  del contraste de regresión:  $F(2, 35) = 223.1866$ , que está bastante cercano a  $W^0/2$ .
- Claramente, se rechaza  $H_0$  (el p-valor es prácticamente 0).

