

# Análisis de Regresión Múltiple: Inferencia

Carlos Velasco<sup>1</sup>

<sup>1</sup>Departamento de Economía  
Universidad Carlos III de Madrid

Econometría I  
Máster en Economía Industrial  
Universidad Carlos III de Madrid  
Curso 2007/08

- 1 Distribuciones muestrales de los Estimadores MCO
- 2 Contraste de Hipótesis sobre un único parámetro poblacional: el test de la  $t$
- 3 Intervalos de Confianza
- 4 Contraste de hipótesis acerca de una única combinación lineal de parámetros
- 5 Contraste de múltiples restricciones lineales: el contraste de la  $F$
- 6 Presentación de resultados de regresión

# Contraste de hipótesis sobre los parámetros del modelo de regresión poblacional

- Distribución en el muestreo de los EMCO (normalidad).
- Contraste de hipótesis sobre parámetros individuales.
- Contraste de hipótesis sobre más de un parámetro.
- Contraste de restricciones múltiples (grupos de parámetros).

# 1. Distribuciones muestrales de los Estimadores MCO

- 1 Distribuciones muestrales de los Estimadores MCO
- 2 Contraste de Hipótesis sobre un único parámetro poblacional: el test de la  $t$
- 3 Intervalos de Confianza
- 4 Contraste de hipótesis acerca de una única combinación lineal de parámetros
- 5 Contraste de múltiples restricciones lineales: el contraste de la  $F$
- 6 Presentación de resultados de regresión

- Hemos introducido supuestos que garantizan que los EMCO son **insesgados** y el cálculo de sus **varianzas** bajo las condiciones de Gauss-Markov.
- La varianza y el valor esperado de los EMCO son útiles para describir su **precisión**.
- Para hacer inferencia estadística se necesita además conocer la **distribución muestral** de los EMCO  $\hat{\beta}_j$ .
- La distribución de los EMCO depende de la distribución de los errores.

**RLM.6** (Normalidad) El error poblacional  $u$  es independiente de las variables explicativas  $x_1, x_2, \dots, x_k$  y se distribuye normalmente con media cero y varianza  $\sigma^2$ ,  $u \sim Normal(0, \sigma^2)$ .

- RLM.6 es un supuesto mucho más fuerte que los anteriores. Como  $u$  es independiente de  $x_j$ ,

$$\begin{aligned}E(u|x_1, x_2, \dots, x_k) &= E(u) = 0 \\ \text{Var}(u|x_1, x_2, \dots, x_k) &= \text{Var}(u) = \sigma^2,\end{aligned}$$

por lo que implica RLM.3 y RLM.5.

- RLM.1-6 se nombran como los **supuestos clásicos** del modelo de regresión lineal (**MLC**), y al modelo que satisface estos supuestos como el **modelo lineal clásico**: satisface las condiciones de Gauss-Markov junto con el supuesto de normalidad.
- Bajo **MLC** los EMCO  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$  satisfacen una propiedad de eficiencia más fuerte que bajo Gauss-Markov: los EMCO son los estimadores **insesgados de mínima varianza** (ya no se requiere que sean lineales).

- Un resumen de las condiciones MLC para el modelo poblacional es

$$y|\mathbf{x} \sim \text{Normal} \left( \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_k x_k, \sigma^2 \right),$$

donde  $\mathbf{x} = (x_1, x_2, \dots, x_k)$ .

- **Justificación** de la normalidad: como  $u$  es el resultado de la suma de muchos factores inobservables que afectan a  $y$ , se puede invocar el Teorema Central del Límite.

## Distribuciones muestrales de los EMCO (2)

- **Problemas:** cada factor puede tener distribuciones muy distintas en la muestra.
- El TCL asume aditividad de esos factores.
- En la práctica, esta es una cuestión empírica, no hay resultados que digan si  $wage|educ, exper, tenure$  es normal. Pero si se puede razonar que hay problemas:  $wage$  no puede ser negativo (ni menor que un salario mínimo), por lo que en principio se puede pensar que la aproximación normal no es un buen supuesto. Tampoco lo es  $narr86$ , número de arrestos en 1986.
- A veces, ciertas transformaciones, como logs, hacen que las distribuciones se aproximen más a la normal.

# Distribuciones muestrales de los EMCO

Normalidad de los errores se traslada a normalidad de las distribuciones muestrales de los EMCO.

**Teorema 4.1** (Distribuciones muestrales normales). Bajos los supuestos MLC, RLM.1-6, condicional en los valores muestrales de las variables independientes,

$$\hat{\beta}_j \sim \text{Normal} \left( \beta_j, \text{Var} \left( \hat{\beta}_j \right) \right),$$

donde

$$\text{Var} \left( \hat{\beta}_j \right) = \frac{\sigma^2}{SST_j \left( 1 - R_j^2 \right)}$$

y por tanto

$$\frac{\hat{\beta}_j - \beta_j}{sd \left( \hat{\beta}_j \right)} \sim \text{Normal} (0, 1).$$

- Prueba: inmediata si tenemos en cuenta que

$$\hat{\beta}_j - \beta_j = \sum_{i=1}^n w_{ij} u_i$$

donde  $w_{ij} = \hat{r}_{ij}/SSR_j$ , y  $\hat{r}_{ij}$  son los residuos de la regresión MCO de  $x_j$  sobre el resto de variables independientes y  $SSR_j$  es la suma de cuadrados de los residuos de dicha regresión.

- Por tanto podemos tomar  $w_{ij}$  como fijos y usar que la combinación lineal de normales independientes es también normal, con su correspondiente esperanza y varianza.
- La 2ª conclusión es simplemente una estandarización de  $\hat{\beta}_j$ .
- Además obtenemos que cualquier **combinación lineal** de  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$  se distribuye también como una normal y que cualquier subconjunto de  $\hat{\beta}_j$  también es normal.
- En el Tema 5 veremos que sin RLM.6 los  $\hat{\beta}_j$  se distribuyen **aproximadamente como normales en muestras grandes.**

## 2. Contraste de Hipótesis sobre un único parámetro poblacional: el test de la $t$

- 1 Distribuciones muestrales de los Estimadores MCO
- 2 Contraste de Hipótesis sobre un único parámetro poblacional: el test de la  $t$
- 3 Intervalos de Confianza
- 4 Contraste de hipótesis acerca de una única combinación lineal de parámetros
- 5 Contraste de múltiples restricciones lineales: el contraste de la  $F$
- 6 Presentación de resultados de regresión

# Contraste de Hipótesis sobre un único parámetro poblacional: el test de la $t$

Modelo poblacional, bajo MLC,

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_k x_k + u.$$

- El problema es hacer contrastes de hipótesis sobre  $\beta_j$ .
- $\beta_j$  es una propiedad desconocida de la población, y nunca la conoceremos con certeza, pero podemos hacer **hipótesis** sobre su valor, y hacer **inferencia estadística** para contrastar nuestra hipótesis.

# Contraste de Hipótesis sobre un único parámetro poblacional: el test de la $t$

**Teorema 4.2** (Distribución del estimador MCO estandarizado). Bajos los supuestos MLC, RLM.1-6,

$$\frac{\hat{\beta}_j - \beta_j}{\text{se}(\hat{\beta}_j)} \sim t_{n-k-1},$$

donde  $k + 1$  es el número de parámetros desconocidos en el modelo poblacional  $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$ .

Diferencias con el Teorema 4.1:

- En el Teorema 4.1 teníamos que  $(\hat{\beta}_j - \beta_j) / \text{sd}(\hat{\beta}_j)$  era  $N(0, 1)$ , pero ahora se estima  $\sigma$ , por lo que la distribución es  $t$ .
- Entonces se puede escribir  $(\hat{\beta}_j - \beta_j) / \text{se}(\hat{\beta}_j)$  como el cociente de una variable  $N(0, 1)$  y una  $\chi^2_{n-k-1}$ , independientes.

# Contraste de Hipótesis sobre un único parámetro poblacional: el test de la $t$

- El Teorema 4.2 es importante porque permite contrastar hipótesis sobre  $\beta_j$ .
- En la mayoría de las aplicaciones, el interés primordial es contrastar la **hipótesis nula**

$$H_0 : \beta_j = 0.$$

- Significado: como  $\beta_j$  mide el efecto parcial de  $x_j$  sobre (el valor esperado de)  $y$ , después de controlar por todas las otras variables independientes,  $H_0$  significa que, una vez que se ha tenido en cuenta  $x_1, \dots, x_{j-1}, x_{j+1}, \dots, x_k$ ,  $x_j$  **no tiene efecto** sobre el valor esperado de  $y$ .

# Contraste de Hipótesis: el test de la $t$

Ejemplo: ecuación de salarios

$$\log(\text{wage}) = \beta_0 + \beta_1 \text{educ} + \beta_2 \text{exper} + \beta_3 \text{tenure} + u$$

- La hipótesis nula

$$H_0 : \beta_2 = 0$$

significa que, una vez que se ha tenido en cuenta educación y antigüedad, el número de años en la población activa no tiene efecto sobre el salario por hora.

- Esto tiene importantes consecuencias económicas: si esto es cierto, la historia previa de la persona al empleo actual no tiene influencia sobre su salario.
- Si  $\beta_2 > 0$  querría decir que la experiencia pasada contribuye a la productividad y por tanto al salario.

# Contraste de Hipótesis: el test de la $t$

## Mecánica de contraste

- Es similar al contraste de la media de la población.
- Incluye obtener los estimadores de los coeficientes, sus errores estándar, el estadístico de contraste, y los valores de contraste: todo esto lo hace el Eviews.
- El estadístico de contraste se llama **estadístico  $t$**  o cociente  $t$  ( $t$  ratio) de  $\hat{\beta}_j$  :

$$t_{\hat{\beta}_j} = \frac{\hat{\beta}_j}{se(\hat{\beta}_j)}.$$

# Contraste de Hipótesis: el test de la $t$

¿Porqué el **estadístico**  $t$  es razonable para contrastar  $H_0$ ?

- $t_{\hat{\beta}_j}$  siempre tiene el signo de  $\hat{\beta}_j$ , porque  $se(\hat{\beta}_j)$  es positivo.
- Para un valor fijo de  $se(\hat{\beta}_j)$ , cuanto mayor  $\hat{\beta}_j$ , mayor  $t_{\hat{\beta}_j}$ , en valor absoluto.
- $\hat{\beta}_j$  es un estimador insesgado de  $\beta_j$ , pero nunca será igual a cero, con  $H_0$  cierta o falsa.
- La pregunta clave es, ¿está  $\hat{\beta}_j$  cerca o lejos de cero?
- Un valor de  $\hat{\beta}_j$  lejano de cero proporciona evidencia en contra de  $H_0$ , pero la estimación está sometida a un error de muestreo.
- $t_{se(\hat{\beta}_j)}$  mide cuántas desviaciones estándar estimadas está  $\hat{\beta}_j$  de cero.
- La regla de rechazo dependerá de la hipótesis alternativa correspondiente y del nivel de significación elegido.

# Contraste de Hipótesis: el test de la $t$

## Regla de rechazo

- Determinar la regla de rechazo dado un nivel de significación (probabilidad de rechazar  $H_0$  cuando es cierta) requiere conocimiento de la distribución muestral de  $t_{\hat{\beta}_j}$  cuando  $H_0$  es verdad:  $t_{n-k-1}$ .
- Mantenemos el signo de  $t_{\hat{\beta}_j}$  para hacer hacer hipótesis unilaterales.
- Clave: contrastamos hipótesis sobre los parámetros poblaciones, no sobre los estimadores obtenidos para una muestra en particular:
- Hipótesis absurdas:

$$H_0 : \hat{\beta}_j = 0. \quad H_0 : 0,434 = 0.$$

# Contraste de Hipótesis: el test de la $t$

## Contraste de hipótesis unilaterales

$$H_1 : \beta_j > 0.$$

- Esto significa que no nos preocupamos de alternativas de  $H_0$  para las que  $H_1 : \beta_j < 0$ . Por alguna razón descartamos que  $\beta_j < 0$ .
- Regla de decisión: necesitamos un **nivel de significación** o probabilidad de rechazar  $H_0$  cuando es cierta (error de tipo I), por ejemplo 5%.
- Como  $t_{\hat{\beta}_j}$  se distribuye como una  $t$  bajo  $H_0$ , por lo que tiene media cero, bajo la alternativa  $\beta_j > 0$ , el valor esperado de  $t_{\hat{\beta}_j}$  es positivo: buscamos un valor suficientemente grande (y positivo) de  $t_{\hat{\beta}_j}$  para rechazar  $H_0 : \beta_j = 0$  en favor de  $H_1 : \beta_j > 0$ .
- Valores negativos de  $\hat{\beta}_j$  o  $t_{\hat{\beta}_j}$  no proporcionan evidencia en favor de  $H_1$ .

# Contraste de Hipótesis: el test de la $t$

## Contraste de hipótesis unilaterales (2)

- La definición de "suficientemente grande", con un 5% de nivel de significación, es el percentil 95% en una  $t_{n-k-1}$ ,  $c$ .
- Por tanto la regla de rechazo es que  $H_0$  se rechaza en favor de  $H_1$ , al nivel de significación del 5%, si

$$t_{\hat{\beta}_j} > c.$$

- Por nuestra elección de  $c$ , esto ocurrirá el 5% de todas las muestras cuando  $H_0$  sea cierta.
- Este es un contraste de una sola cola (unilateral): Un valor negativo de  $t_{\hat{\beta}_j}$  nunca rechazará  $H_0$ .
- Para otros valores se procederá igual: mayor nivel de significación implicará que  $c$  es más pequeño, y por tanto se rechazará  $H_0$  más veces cuando es cierta.
- Por tanto, si  $H_0$  se rechaza al 5%, también se rechazará al 10%.
- Cuanto más grande es  $n$ , más se parece la  $t$  a la normal.

# Contraste de Hipótesis: el test de la $t$

Contraste de hipótesis unilaterales: Ejemplo ecuación salarial

$$\widehat{\log(wage)} = 0,2844 + 0,092 educ + 0,0041 exper + 0,0221 tenure$$

(0,1042)      (0,0073)                      (0,0017)                      (0,0031)

$$n = 526, \quad R^2 = 0,316 \quad \text{WAGE1.RAW}$$

- Hipótesis: el efecto de *exper*, una vez descontado el efecto de *educ* y *tenure*, es cero en la población. Alternativa: es positivo.

$$H_0 : \beta_{exper} = 0 \quad \text{contra} \quad H_1 : \beta_{exper} > 0.$$

$$t_{\hat{\beta}_{exper}} = \frac{0,00412111}{0,0017233} = 2,3914,$$

por tanto  $\hat{\beta}_{exper}$ , o *exper*, es estadísticamente significativo incluso al 1 por ciento (o  $\hat{\beta}_{exper}$  es estadísticamente mayor que cero.)

- El efecto no es muy grande (tres años más de experiencia aportan un salario 1.2 % mayor,) pero ese efecto es positivo. ☰ ↶ ↷ ↻

# Contraste de Hipótesis: el test de la $t$

## Contraste de hipótesis unilaterales (3)

- Hipótesis alternativa

$$H_1 : \beta_j < 0.$$

- La regla de rechazo es que  $H_0$  se rechaza en favor de  $H_1$ , al nivel de significación del 5%, si

$$t_{\hat{\beta}_j} < -c.$$

# Contraste de Hipótesis: el test de la $t$

## Contraste de hipótesis bilaterales

- En aplicaciones es frecuente contrastar la hipótesis nula  $H_0 : \beta_j = 0$  contra una **alternativa bilateral**,

$$H_1 : \beta_j \neq 0.$$

- Bajo esta alternativa,  $x_j$  tiene un efecto ceteris paribus sobre  $y$  sin especificar si éste es positivo o negativo. Esta es la alternativa relevante cuando el signo de  $\beta_j$  no está determinado por la teoría (o el sentido común). Incluso si se conoce el signo de  $\beta_j$  bajo la alternativa, un test bilateral es en general prudente (ya que por ejemplo no depende del signo de  $\hat{\beta}_j$ ).
- Si no se especifica una alternativa concreta, en general se hace el contraste bilateral, y el 5% será el nivel de significación por defecto. Eviews y la mayoría de los paquetes hacen este contraste también por defecto para todos los  $x_j$ .

# Contraste de Hipótesis: el test de la $t$

## Contraste de hipótesis bilaterales (2)

- Regla de rechazo:  $H_0$  se rechaza en favor de  $H_1$ , al nivel de significación del 5 %, si

$$\left| t_{\hat{\beta}_j} \right| > c,$$

donde  $c$  es el valor crítico que deja en cada área 2,5 % de probabilidad en una distribución  $t_{n-k-1}$ .

- Si  $H_0$  se **rechaza** en favor de  $H_1$  al 5 % se habla de que  $x_j$  es **estadísticamente significativo** (o estadísticamente diferente de cero).
- Si se rechaza a niveles de significación muy pequeños, entonces se habla que  $x_j$  es estadísticamente significativo a cualquier nivel de significación *habitual* (convencional).

# Contraste de Hipótesis: el test de la $t$

Otras hipótesis sobre  $\beta_j$

- En general podemos estar interesados en contrastar

$$H_0 : \beta_j = a_j$$

donde  $a_j$  es un valor hipotético para  $\beta_j$ .

- El estadístico  $t$  apropiado es

$$t = \frac{\hat{\beta}_j - a_j}{se(\hat{\beta}_j)}.$$

- $t$  mide el número de desviaciones estándar estimadas que  $\hat{\beta}_j$  está del valor hipotético  $a_j$ .
- El estadístico  $t$  se puede usar para contrastar  $H_0$  en contra de alternativas uni- o bilaterales, con el mismo valor crítico.
- Unilaterales: Si se rechaza  $H_0$  en favor de  $H_1 : \beta_j > 1$ , se dice que  $\hat{\beta}_j$  es estadísticamente mayor que 1 al nivel de significación correspondiente.

# Contraste de Hipótesis: el test de la $t$

Otras hipótesis sobre  $\beta_j$  : Ejemplo: delincuencia en los campus y matrícula

- Modelo con elasticidad constante:

$$\log(\text{crime}) = \beta_0 + \beta_1 \log(\text{enroll}) + u.$$

- En este caso la hipótesis de interés es

$$H_0 : \beta_1 = 1.$$

Si  $\beta_1 > 1$  entonces la delincuencia se incrementa más que proporcionalmente con el tamaño del campus, y afecta relativamente más a campus grandes.

- Para comparar las situaciones  $\beta_1 <, =, > 1$  en términos absolutos se puede usar el modelo en niveles

$$\text{crime} = \exp(\beta_0) \text{enroll}^{\beta_1} \exp(u).$$

# Contraste de Hipótesis: el test de la $t$

Otras hipótesis sobre  $\beta_j$  : Ejemplo: delincuencia en los campus y matrícula (2)

- Ecuación estimada:

$$\widehat{\log(\text{crime})} = \underset{(1,03)}{-6,63} + \underset{(0,11)}{1,27} \log(\text{enroll})$$

$$n = 97, \quad R^2 = 0,585$$

- $\hat{\beta}_1 > 1$ , pero hay evidencia para rechazar  $H_0 : \beta_1 = 1$  en contra de

$$H_1 : \beta_1 > 1?$$

- Contraste:

$$t = \frac{\hat{\beta}_j - a_j}{\text{se}(\hat{\beta}_j)} = \frac{1,27 - 1}{0,11} = \frac{0,27}{0,11} \approx 2,45.$$

El valor crítico de un lado de una  $t_{97-2} = t_{95}$  al nivel del 5% es 1,66 (aproximando con la  $t_{120}$ ), por lo que rechazamos  $H_0$  claramente en favor de  $H_1$ . (Valor crítico al 1%: 2.37).

# Contraste de Hipótesis: el test de la $t$

## p-valores para contrastes de la $t$

- Método tradicional para contrastar hipótesis: elegir un **nivel de significación** y buscar un **valor crítico** para comparar con el  $t$ .
- Esto tiene un grado de **arbitrariedad**: la elección del nivel de significación antes del contraste, pero no hay uno correcto o mejor.
- Este procedimiento omite información importante sobre el resultado de un contraste: sólo sabemos que para un nivel de significación particular se acepta o rechaza  $H_0$ , pero no que ocurre a cualquier otro.
- Mejor responder: dado el valor del estadístico  $t$ , ¿cuál es el *menor* nivel de significación para el que la hipótesis nula se rechaza? El p-valor es una probabilidad  $\in (0, 1)$ .
- Este valor es el **p-valor** del contraste. Se obtiene usando la distribución de una variable  $t_{n-k-1}$  y comparándola con el valor del estadístico  $t$ .

# Contraste de Hipótesis: el test de la $t$

## p-valores para contrastes de la $t$ (2)

- Los paquetes (Eviews) calculan el p-valor para contrastes de hipótesis particulares:

$$H_0 : \beta_j = 0, \quad \text{en contra de } H_1 : \beta_j \neq 0,$$

para el que

$$\text{p-valor} = \Pr(|t_{n-k-1}| > |t|)$$

donde  $t$  es el valor numérico del contraste.

- El p-valor resume la fuerza o debilidad de la evidencia empírica contra la hipótesis nula.
- El p-valor es la probabilidad de observar un estadístico  $t$  tan extremo (o más) como el que obtuvimos si la hipótesis nula fuese cierta:
  - p-valores pequeños son evidencia en contra  $H_0$ .
  - p-valores grandes son **poca** evidencia contra  $H_0$ .

# Contraste de Hipótesis: el test de la $t$

p-valores para contrastes de la  $t$  : Ejemplo

Si tenemos que los grados de libertad son  $n - k - 1 = 40$  y  $t = 1,85$ , entonces

$$p\text{-valor} = \Pr(|t_{40}| > |1,85|) = 2 \Pr(t_{40} > 1,85) = 2 * 0,0359 = 0,0718.$$

Esto proporciona cierta evidencia en contra de  $H_0$ , pero no se rechazará  $H_0$  en favor de  $H_1$  al 5%.

- ¿Qué ocurrirá al 10%?
- ¿Y al 1%?
- Si obtenemos el p-valor podemos efectuar contrastes clásicos a cualquier nivel de significación:
  - Si  $\alpha$  es mayor que el p-valor rechazamos  $H_0$  al nivel de significación  $\alpha$
  - si  $\alpha$  es menor que el p-valor no podemos rechazar  $H_0$ .

# Contraste de Hipótesis: el test de la $t$

p-valor para contrastes de la  $t$ . Contrastes unilaterales

- $$H_0 : \beta_j = 0, \quad \text{en contra de } H_1 : \beta_j > 0.$$

- Si  $\hat{\beta}_j < 0$ , entonces calcular el p-valor no es importante: es mayor que 0,5, por lo que nunca rechazaremos  $H_0$  en favor de  $H_1$ .
- Si  $\hat{\beta}_j > 0$  entonces  $t > 0$  y

$$p\text{-valor} = \Pr(t_{n-k-1} > t).$$

- Este p-valor es igual a la mitad del p-valor de la hipótesis bilateral.
- Si

$$H_0 : \beta_j = 0, \quad \text{en contra de } H_1 : \beta_j < 0.$$

- Si  $\hat{\beta}_j < 0$  entonces  $t < 0$  y

$$p\text{-valor} = \Pr(t_{n-k-1} < t).$$

# Contraste de Hipótesis: el test de la $t$

## Comentarios

- Cuando  $H_0$  no es rechazada hablamos de que "**no podemos rechazar  $H_0$**  al nivel  $\alpha$ ", en lugar de que "se acepta  $H_0$  al nivel  $\alpha$ ."
- La **significación estadística** de una variable  $x_j$  viene determinada por el tamaño de  $t_{\hat{\beta}_j}$ .
- La **significación económica** o la significación práctica de una variable está relacionada con el tamaño (y el signo) de  $\hat{\beta}_j$ .
- $t_{\hat{\beta}_j}$  puede indicar significatividad estadística bien porque  $\hat{\beta}_j$  es grande o porque se  $\left(\hat{\beta}_j\right)$  es pequeño (por ejemplo porque  $n$  es muy grande): una variable puede ser estadísticamente significativa pero tener un efecto pequeño para explicar  $y$ .
- Ejemplo: Planes de pensiones 401(k) y el efecto de  $totemp$  :

$$prate = \beta_0 + \beta_1 mrate + \beta_2 age + \beta_3 totemp + u.$$

- A veces se sugiere cambiar los niveles de significación con el tamaño muestral.
- Los errores estándar pueden a veces ser muy altos por un problema de multicolinealidad:
  - Debemos aumentar el tamaño muestral.
  - O cambiar el objetivo del análisis.

# Contraste de Hipótesis: el test de la $t$

## Comentarios (3)

- Guía:
  - Comprobar la significación estadística de una variable y luego discutir la significación económica.
  - Si una variable no es significativa a los niveles habituales, todavía nos podemos plantear si tiene el efecto esperado sobre  $y$  y si este efecto es grande en términos prácticos. Si es grande, se debe computar el  $p$ -valor.
- Es frecuente encontrar variables con estadísticos  $t$  pequeños que tienen el signo equivocado: en la práctica estas variables deben ser ignoradas.

Una variable significativa estadísticamente y con el signo cambiado es mucho más preocupante y difícil de resolver. Hay que repensar el modelo (omisión de variables, forma funcional, etc.).

## 3. Intervalos de Confianza

- 1 Distribuciones muestrales de los Estimadores MCO
- 2 Contraste de Hipótesis sobre un único parámetro poblacional: el test de la  $t$
- 3 Intervalos de Confianza
- 4 Contraste de hipótesis acerca de una única combinación lineal de parámetros
- 5 Contraste de múltiples restricciones lineales: el contraste de la  $F$
- 6 Presentación de resultados de regresión

# Intervalos de Confianza

- También estimadores por intervalos: Proporcionan un rango de valores probables para el valor del parámetro poblacional.

- Intervalo al 95 % :

$$\hat{\beta}_j \pm c \cdot se(\hat{\beta}_j)$$

donde  $c$  es el cuantil 97.5 de la distribución  $t_{n-k-1}$ .

- Alternativamente

$$\left( \hat{\beta}_j - c \cdot se(\hat{\beta}_j), \hat{\beta}_j + c \cdot se(\hat{\beta}_j) \right).$$

- Significado: si se obtienen sucesivas muestras aleatorias y se computa el intervalo de confianza para cada una de ellas, entonces el valor poblacional  $\beta_j$  (desconocido) estará contenido en el intervalo de confianza para un 95 % de las muestras.
- Para un intervalo de confianza en particular, no hay ninguna seguridad de que contenga el valor  $\beta_j$ .

## Intervalos de Confianza (2)

- Para construir el intervalo de confianza hacen falta tres elementos:
  - $\hat{\beta}_j$ .
  - $c$ , que depende del cuantil de la  $t_{n-k-1}$ . Si  $n$  es grande se puede aproximar por la normal y si el nivel de confianza es del 95 % podemos aproximar  $c \approx 2$ .
  - $se(\hat{\beta}_j)$ .
- Para otros niveles de confianza se opera igual: a mayor nivel de confianza, más amplio es el intervalo.
- Con un intervalo de confianza es inmediato realizar **contrastes de hipótesis bilaterales**:

Si la hipótesis nula es  $H_0 : \beta_j = a_j$ , entonces  $H_0$  es rechazada en favor de  $H_1 : \beta_j \neq a_j$  al nivel de significación del 5 % si y sólo si  $a_j$  no está contenida en el intervalo de confianza al 95 %.

# Intervalos de Confianza

Ejemplo: Modelo para precios hedónicos de viviendas

$$\widehat{\log(\text{price})} = \underset{(1,15)}{7,46} + \underset{(.184)}{0,634} \log(\text{sqrft}) - \underset{(.059)}{0,066} \text{bdrms} + \underset{(.075)}{0,158} \text{bthrms}$$
$$n = 19, \quad R^2 = 0,806$$

- La elasticidad respecto a la superficie es .634.
- Usando la distribución  $t_{n-k-1} = t_{15}$  podemos obtener el cuantil 97.5% igual a  $c = 2,131$ .
- Intervalo de confianza al 95% para  $\beta_{\log(\text{sqrft})}$ :

$$0,634 \pm 2,131 \cdot 0,184 \quad \equiv \quad (,242, 1,026).$$

- Se rechaza  $H_0 : \beta_{\log(\text{sqrft})} = 0$  en favor de la altern. bilateral al 5%.
- El coeficiente de *bdrms* es negativo: pensar interpretación cp.

# Intervalos de Confianza

Ejemplo: Modelo para precios hedónicos de viviendas (2)

$$\widehat{\log(\text{price})} = 7,46 + 0,634 \log(\text{sqrft}) - 0,066 \text{bdrms} + 0,158 \text{bthrms}$$

(1,15)            (,184)                            (,059)                            (,075)

$$n = 19, \quad R^2 = 0,806$$

- Intervalo de confianza para  $\beta_{\text{bdrms}}$  :

$$-0,066 \pm 2,131 \cdot 0,059 \quad \equiv \quad (-,192, ,060).$$

- $H_0 : \beta_{\text{bdrms}} = 0?$

- IC para  $\beta_{\text{bthrms}}$ :

$$(-0,002, ,318).$$

- $H_0 : \beta_{\text{bthrms}} = 0?$

## 4. Contraste de hipótesis acerca de una única combinación lineal de parámetros

- 1 Distribuciones muestrales de los Estimadores MCO
- 2 Contraste de Hipótesis sobre un único parámetro poblacional: el test de la  $t$
- 3 Intervalos de Confianza
- 4 Contraste de hipótesis acerca de una única combinación lineal de parámetros
- 5 Contraste de múltiples restricciones lineales: el contraste de la  $F$
- 6 Presentación de resultados de regresión

# Contraste de hipótesis acerca de una única combinación lineal de parámetros

- En la práctica es frecuente tener que contrastar hipótesis sobre más de un parámetro poblacional (y también múltiples hipótesis).
- EJEMPLO: modelo para comparar el rendimiento de la educación en escuelas universitarias y facultades para una población de trabajadores con el título de bachillerato:

$$\log(\text{wage}) = \beta_0 + \beta_1 jc + \beta_2 univ + \beta_3 exper + u$$

- $jc$  = número de años como estudiante en una escuela universitaria.
- $univ$  = número de años en una universidad.
- Hipótesis de interés: un año en una escuela universitaria tiene el mismo valor que un año en la universidad, cp:

$$H_0 : \beta_1 = \beta_2$$

# Contraste de hipótesis acerca de una única combinación lineal de parámetros

- Hipótesis alternativa (unilateral): un año en la escuela primaria vale menos que un año en una universidad:

$$H_1 : \beta_1 < \beta_2.$$

- $H_0$  y  $H_1$  se refieren a dos parámetros,  $\beta_1$  y  $\beta_2$  : no es suficiente con los estadísticos  $t$  individuales.
- Se reescriben las hipótesis:

$$H_0 : \beta_1 - \beta_2 = 0, \quad H_1 : \beta_1 - \beta_2 < 0.$$

- Nuevo estadístico  $t$ , para comparar  $\hat{\beta}_1 - \hat{\beta}_2$  con  $\beta_1 - \beta_2$  bajo  $H_0$ :

$$t = \frac{\hat{\beta}_1 - \hat{\beta}_2}{\text{se}(\hat{\beta}_1 - \hat{\beta}_2)}.$$

- Regla de rechazo: se rechaza  $H_0$  cuando  $t < -c$  donde  $c$  es un valor crítico de la distribución  $t$ .
- Única novedad: cálculo del error estándar.

# Contraste de hipótesis acerca de una única combinación lineal de parámetros

Ejemplo: salarios, TWOYEAR

$$\log(\text{wage}) = \beta_0 + \beta_1 \text{jc} + \beta_2 \text{univ} + \beta_3 \text{exper} + u$$

$$\widehat{\log(\text{wage})} = 1,4723 + 0,0667 \text{jc} + 0,0769 \text{univ} + 0,0049 \text{exper}$$

(0,021)            (0,0068)            (0,0023)            (0,00016)

$$n = 6763 \quad R^2 = 0,222$$

- Se predice una diferencia porcentual de aproximadamente un 1 % :

$$\hat{\beta}_1 - \hat{\beta}_2 = -0,0102.$$

# Contraste de hipótesis acerca de una única combinación lineal de parámetros

Ejemplo: salarios, TWOYEAR (2)

$$\widehat{\log(wage)} = \underset{(0,021)}{1,4723} + \underset{(0,0068)}{0,0667}jc + \underset{(0,0023)}{0,0769}univ + \underset{(0,00016)}{0,0049}exper$$
$$n = 6763 \quad R^2 = 0,222$$

- No hay información para calcular  $se(\hat{\beta}_1 - \hat{\beta}_2)$ , pero

$$Var(\hat{\beta}_1 - \hat{\beta}_2) = Var(\hat{\beta}_1) + Var(\hat{\beta}_2) - 2Cov(\hat{\beta}_1, \hat{\beta}_2)$$

y por tanto

$$se(\hat{\beta}_1 - \hat{\beta}_2) = \left\{ se(\hat{\beta}_1)^2 + se(\hat{\beta}_2)^2 - 2\widehat{Cov}(\hat{\beta}_1, \hat{\beta}_2) \right\}^{1/2}$$

- Eviews proporciona  $\widehat{Cov}(\hat{\beta}_1, \hat{\beta}_2)$ .

# Contraste de hipótesis acerca de una única combinación lineal de parámetros

## Otro método

- Basado en un modelo alternativo: evita tener que calcular  $\widehat{Cov}(\hat{\beta}_1, \hat{\beta}_2)$  y  $se(\hat{\beta}_1 - \hat{\beta}_2)$ .
- Se basa en una reparametrización del modelo lineal:

$$\theta_1 = \beta_1 - \beta_2$$

y el contraste se realiza acerca de

$$H_0 : \theta_1 = 0, \quad H_1 : \theta_1 < 0$$

a partir de

$$t = \frac{\hat{\theta}_1}{se(\hat{\theta}_1)}$$

- $\theta_1$  debe ser el coeficiente de una de las variables explicativas del modelo.

# Contraste de hipótesis acerca de una única combinación lineal de parámetros

## Otro método (2)

- Usando  $\theta_1 = \beta_1 - \beta_2$ , y por tanto  $\beta_1 = \theta_1 + \beta_2$ ,

$$\log(\text{wage}) = \beta_0 + \overbrace{(\theta_1 + \beta_2)}^{=\beta_1} jc + \beta_2 univ + \beta_3 exper + u$$

$$\log(\text{wage}) = \beta_0 + \theta_1 jc + \beta_2 (jc + univ) + \beta_3 exper + u$$

- La clave es que el parámetro de interés,  $\theta_1$ , es ahora el coeficiente de una variable y se puede estimar directamente por MCO.
- Además hay una nueva variable que multiplica a  $\beta_3$ ,  $jc + univ = totcoll$ , en lugar de  $univ$ ,

$$\log(\text{wage}) = \beta_0 + \theta_1 jc + \beta_2 totcoll + \beta_3 exper + u.$$

- El parámetro  $\beta_1$  ha desaparecido del modelo, mientras que  $\theta_1$  aparece explícitamente, e Eviews reportará  $se(\hat{\theta}_1)$ .

# Contraste de hipótesis acerca de una única combinación lineal de parámetros

## Otro método (3)

- Si estimamos por MCO:

$$\log(\widehat{wage}) = \underset{(0,02106)}{1,47233} - \underset{(0,0069)}{0,0102}jc + \underset{(0,00016)}{0,0769}totcoll + \underset{(0,00016)}{0,0049}exper$$
$$n = 6763 \quad R^2 = 0,222$$

- El único resultado nuevo es el *se* de  $\hat{\theta}_1$ ,  $se(\hat{\theta}_1) = 0,0069$  :

$$t_{\theta_1} = \frac{-0,0102}{0,0069} = -1,478.$$

El p-valor contra una alternativa unilateral es sobre 0.7, por lo que hay evidencia contra  $H_0$ , pero no muy fuerte.

- El coeficiente y el *se* de *exper* deben ser iguales.
- El coeficiente de *totcoll* y su *se* deben ser iguales a los que tenía *univ*.

## 5. Contraste de múltiples restricciones lineales: el contraste de la $F$

- 1 Distribuciones muestrales de los Estimadores MCO
- 2 Contraste de Hipótesis sobre un único parámetro poblacional: el test de la  $t$
- 3 Intervalos de Confianza
- 4 Contraste de hipótesis acerca de una única combinación lineal de parámetros
- 5 Contraste de múltiples restricciones lineales: el contraste de la  $F$
- 6 Presentación de resultados de regresión

# Contraste de múltiples restricciones lineales: el contraste de la $F$

## Contraste de restricciones de exclusión

- Hasta ahora sólo hemos abordado problemas sobre una sola restricción.
- El primer problema es contrastar si un **grupo** de variables no tiene efecto sobre la variable dependiente, una vez que se ha controlado por otro grupo de variables.

# Contraste de restricciones de exclusión

EJEMPLO: salarios de una liga de baseball

$$\log(\text{salary}) = \beta_0 + \beta_1 \text{years} + \beta_2 \text{gamesyr} + \beta_3 \text{bavg} + \beta_4 \text{hrunsyr} + \beta_5 \text{rbisyr} + u$$

- *years* : años en la liga.
- *gamesyr* = número medio de partidos jugados al año.
- *bavg* = número medio de bateos.
- *hrunsyr* = número de home runs por año
- *rbisyr* = carreras con bateo por año.
- **Contraste de hipótesis múltiple o contraste conjunto:** La hipótesis de interés es que una vez que se ha controlado por el número de años y de partidos por año, las estadísticas que miden el rendimiento, *bavg*, *hrunsyr* y *rbisyr*, no tienen efecto:

$$H_0 : \beta_3 = 0, \beta_4 = 0, \beta_5 = 0.$$

- Son tres **restricciones de exclusión**: si  $H_0$  es cierta, entonces *bavg*, *hrunsyr* y *rbisyr* no deberán estar en el modelo.

# Contraste de restricciones de exclusión

- Hipótesis alternativa:

$$H_1 : H_0 \text{ no es cierta.}$$

- $H_1$  es cierta si al menos uno de  $\beta_3, \beta_4$  ó  $\beta_5$  es diferente de cero.
- El contraste va a detectar cualquier violación de  $H_1$ , como que  $\beta_3 > 0$  o que  $\beta_5 < 0$ , pero en ese caso no será el mejor contraste.
- ¿Cómo proceder? Una primera posibilidad es usar los estadísticos individuales de la  $t$  para las tres variables para determinar si cada una de las variables puede ser eliminada individualmente.
- Sin embargo esto no es apropiado: un estadístico  $t$  no impone restricciones sobre los otros parámetros y no está claro cuántos de ellos deben rechazar para realizar un contraste al 5% de  $H_0$ .

# Contraste de restricciones de exclusión

EJEMPLO: salarios de una liga de baseball (2) MLB1

$$\begin{aligned}\log(\widehat{salary}) &= 11,20 + 0,0689years + 0,0126gamsyr \\ &\quad (0,289) \quad (0,012) \quad (0,0026) \\ &+ 0,00098bavg + 0,0144hrunsyr + 0,0108rbisyr \\ &\quad (0,0011) \quad (0,016) \quad (0,0072) \\ n &= 353, SSR = 183,186, R^2 = 0,6278\end{aligned}$$

- *years* y *gamsyr* son significativas.
- Ninguna de *bavg*, *hrunsyr* y *rbisyr* es significativa individualmente usando las *t*: aparentemente no podemos rechazar  $H_0$ .
- Sin embargo esta conclusión puede estar equivocada: debemos hacer un contraste conjunto de todas las restricciones.
- El nuevo método va a usar la *SSR* del ajuste (o alternativamente el  $R^2$  en el caso de restricciones de exclusión).
- *SSR* no dice nada acerca de que  $H_0$  sea cierta o no: lo importante es cuánto se incrementa *SSR* cuando eliminamos las variables *bavg*, *hrunsyr* y *rbisyr* del modelo.

# Contraste de restricciones de exclusión

EJEMPLO: salarios de una liga de baseball

- **Modelo no restringido:**

$$\log(\text{salary}) = \beta_0 + \beta_1 \text{years} + \beta_2 \text{gamsyr} + \beta_3 \text{bavg} + \beta_4 \text{hrunsyr} + \beta_5 \text{rbisy}$$

- **Modelo restringido:**

$$\log(\text{salary}) = \beta_0 + \beta_1 \text{years} + \beta_2 \text{gamsyr} + u$$

- Modelo restringido ajustado:

$$\log(\widehat{\text{salary}}) = 11,22 + 0,0713 \text{years} + 0,0202 \text{gamsyr}$$

(0,11)                      (0,0125)                      (0,0013)

$$n = 353, SSR = 198,311, R^2 = 0,5971.$$

- $SSR$  aumenta, como se esperaba, y  $R^2$  baja también: hay que decidir si el descenso de  $SSR$  al pasar del modelo sin restringir al restringido es significativo para que se pueda rechazar  $H_0$ .
- Se necesita un estadístico de contraste de distribución conocida y un nivel de significación.

# Contraste de restricciones de exclusión: Estadístico de la $F$

- Modelo no restringido:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_k x_k + u.$$

- Hipótesis nula ( $q$  restricciones):

$$H_0 : \beta_{k-q+1} = 0, \dots, \beta_k = 0.$$

- Modelo restringido:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_{k-q} x_{k-q} + u.$$

- Estadístico de la  $F$  :

$$F = \frac{(SSR_r - SSR_{nr}) / q}{SSR_{nr} / (n - k - 1)} = \frac{SSR_r - SSR_{nr}}{SSR_{nr}} \frac{n - k - 1}{q}$$

- $SSR_{nr}$  : suma de cuadrados de residuos en el modelo no restringido.
- $SSR_r$  : suma de cuadrados de residuos en el modelo restringido.

# Contraste de restricciones de exclusión: Estadístico de la $F$

- $F$  nunca es negativo.
- $q = \text{grados de libertad del numerador} = gl_r - gl_{nr}$ , donde

$gl = \text{número de observaciones} - \text{número de parámetros estimados}$ .

- $n - k - 1 = \text{grados de libertad del denominador: } gl_{nr}$ .
- El denominador de  $F$  es un estimador insesgado de  $\sigma^2$ .
- Ejemplo:

$$\begin{aligned}n &= 353 \\n - k - 1 &= 353 - 5 - 1 = 347 \\q &= 3\end{aligned}$$

# Contraste de restricciones de exclusión: Estadístico de la $F$

## Distribución $F$

- Bajo  $H_0$ ,

$$F \sim F_{q, n-k-1}.$$

- Rechazaremos  $H_0$  cuando  $F$  sea muy grande comparado con la distribución  $F_{q, n-k-1}$ ,

$$F > c.$$

- Si el nivel de significación es del 5%, eligiremos el cuantil del 5%.
- En general  $q$  será pequeño mientras que  $n - k - 1$  será grande: cuando  $n - k - 1 > 120$  la distribución no cambia.
- Si se rechaza  $H_0$  entonces se dice que  $x_{k-q+1}, \dots, x_k$  son **significativos conjuntamente** al nivel de significación apropiado. Pero no sabemos qué variables tienen un efecto parcial sobre  $y$ : puede que sean todas o sólo unas de ellas.
- Si no se rechaza  $H_0$ : "las variables son **conjuntamente no significativas**"

# Contraste de restricciones de exclusión

## Ejemplo

- $n - k - 1 = 347$ ;  $q = 3$
- $F_{3,347}$  :  $c = 2,60$  al 5%,  $c = 3,78$  al 1 %.

$$F = \frac{(198,311 - 183,186) 347}{183,186} \frac{3}{3} \approx 9,55.$$

- Este valor está por encima del valor crítico al 1 % de la  $F_{3,347}$ , por lo rechazamos con bastante fuerza la hipótesis nula de que *bavg*, *hrunsyr* y *rbisy* no tienen efecto sobre el salario.
- Resultado contradictorio con los contrastes *t* individuales.
- El problema es que *hrunsyr* y *rbisy* están muy correladas y esta **multicolinealidad** hace muy complicado aislar el efecto parcial de cada una de las variables.
- Multicolinealidad es mucho menos relevante para contrastar hipótesis conjuntas acerca de variables muy correladas.
- Intenta eliminar *hrunsyr* o *rbisy* del modelo

# Relación entre el Estadístico $F$ y el Estadístico $t$

¿Qué ocurre si se usa el estadístico  $F$  para contrastar si una sola variable es significativa?

- Sería aplicar el método anterior cuando  $q = 1$ , por ejemplo

$$H_0 : \beta_k = 0.$$

- Respuesta: ambos métodos son esencialmente iguales:

$$F = t^2,$$

y como una variable  $t_{n-k-1}^2$  tiene una distribución  $F_{1, n-k-1}$ , los dos métodos proporcionan la misma respuesta.

- El estadístico  $t$  es más flexible para contrastar una sola restricción ya que permite dirigir el contraste contra alternativas unilaterales.

# Estadístico $F$ en función del $R^2$

- En muchas ocasiones se puede usar una forma del estadístico  $F$  en función de los  $R^2$  de los modelos restringido y no restringido.
- Los  $R^2$  pueden ser más convenientes porque están entre 0 y 1 y no depende de las unidades de medida.  
Además se reporta casi siempre, pero quizá no el  $SSR$ .
- La idea es sustituir

$$SSR_r = SST (1 - R_r^2)$$

$$SSR_{nr} = SST (1 - R_{nr}^2)$$

- Entonces

$$F = \frac{(R_{nr}^2 - R_r^2) / q}{(1 - R_{nr}^2) / (n - k - 1)} = \frac{R_{nr}^2 - R_r^2}{1 - R_{nr}^2} \frac{n - k - 1}{q}$$

- Como  $R_{nr}^2 > R_r^2$  el estadístico  $F$  es siempre positivo.

- Ejemplo:

$$F = \frac{(.6278 - .5971) 347}{1 - .6278} \frac{3}{3} \approx 9,54.$$

- **P-valor:** Probabilidad de observar un valor de la  $F$  al menos tan grande como el que se ha obtenido, dada que la hipótesis nula es cierta,

$$p - \text{valor} = Pr (F_{q,n-k-1} > F) .$$

- Permite efectuar contrastes a cualquier nivel de significación.
- Los paquetes econométricos tienen funciones que permiten calcular los  $p$ -valores para restricciones de exclusión.

# El Estadístico $F$ para el contraste de significación global

- Un caso particular muy importante de contraste es aquel en que

$$H_0 : x_1, x_2, \dots, x_k \text{ no ayudan a explicar } y.$$

- Todos los paquetes lo realizan por defecto.
- Hipótesis nula ( $k$  restricciones):

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0.$$

- Alternativa: al menos uno de los  $\beta_j$  es diferente de cero.
- También

$$H_0 : E(y) = E(y|x_1, x_2, \dots, x_k).$$

# El Estadístico $F$ para el contraste de significación global (2)

- Modelo restringido:

$$\begin{aligned}y &= \beta_0 + u, \\ \hat{y} &= \hat{\beta}_0 = \bar{y}, \quad R_r^2 = 0\end{aligned}$$

- Si  $R^2 = R_{nr}^2$  de la regresión de  $y$  sobre  $x_1, x_2, \dots, x_k$ ,

$$F = \frac{R^2/k}{(1 - R^2)/(n - k - 1)} = \frac{R^2}{1 - R^2} \frac{n - k - 1}{k}.$$

- Si no podemos rechazar  $H_0$ , entonces no hay evidencia de que ninguna de las variables independientes ayuden a explicar  $y$  (debemos buscar otras variables que ayuden en ese caso).

# El Estadístico $F$ para el contraste de significación global (3)

Ejemplo: baseball

- Ejemplo baseball:

$$F = \frac{0,6278}{1 - 0,6278} \frac{347}{5} = 117,06$$

y el p-valor es  $< 0,00001$ : se rechaza  $H_0$ , y se concluye que las variables independientes conjuntamente contribuyen a explicar  $y$ .

- El resultado no depende solamente del tamaño del  $R^2$ .

# Contraste de restricciones lineales generales

Ejemplo: precio de la viviendas

$$\log(\text{price}) = \beta_0 + \beta_1 \log(\text{assess}) + \beta_2 \log(\text{lotsize}) \\ + \beta_3 \log(\text{sqrft}) + \beta_4 \text{bdrms} + u$$

- $\text{price}$  = precio de la vivienda.
- $\text{assess}$  = valor de la casa de tasación
- $\text{lotsize}$  = tamaño del lote
- $\text{sqrft}$  = superficie en pies cuadrados
- $\text{bdrms}$  = número de dormitorios
- Hipótesis nula: ver si el precio de tasación es una predicción racional del precio real de venta:

$$\beta_1 = 1.$$

- Además las otras variables no deberían ayudar a predecir el precio de venta una vez que se tiene en cuenta  $\text{assess}$ .
- 4 restricciones, tres de exclusión

$$H_0 : \beta_1 = 1, \beta_2 = 0, \beta_3 = 0, \beta_4 = 0.$$

# Contraste de restricciones lineales generales

Ejemplo: precio de la viviendas (2)

- En este caso también se imponen las restricciones sobre el modelo **no restringido**:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + u$$

para obtener  $y = \beta_0 + x_1 + u$ .

- El modelo **restringido** a estimar:

$$y - x_1 = \beta_0 + u.$$

- Cálculo del estadístico  $F$  : igual que antes:

$$F = \frac{(SSR_r - SSR_{nr}) / q}{SSR_{nr} / (n - k - 1)} = \frac{SSR_r - SSR_{nr}}{SSR_{nr}} \frac{n - k - 1}{q}$$

- NO es posible usar la forma del estadístico  $F$  con  $R^2$  porque la variable dependiente en los dos modelos es diferente:  $SST$  no se cancelaría!!

# Contraste de restricciones lineales generales

Ejemplo: precio de la viviendas (3)

- Estimación modelo no restringido:  $SSR_{nr} = 1,822$ .
- Estimación modelo restringido:  $SSR_r = 1,880$ .
- $n = 88$

$$F = \frac{1,880 - 1,822}{1,822} \frac{83}{4} = 0,661$$

- El valor crítico al 5% de una  $F_{4,83}$  es  $c = 2,50$ , por lo que la hipótesis nula no se puede rechazar: no hay evidencia en contra de que los valores de tasación no son racionales.

## 6. Presentación de resultados de regresión

- 1 Distribuciones muestrales de los Estimadores MCO
- 2 Contraste de Hipótesis sobre un único parámetro poblacional: el test de la  $t$
- 3 Intervalos de Confianza
- 4 Contraste de hipótesis acerca de una única combinación lineal de parámetros
- 5 Contraste de múltiples restricciones lineales: el contraste de la  $F$
- 6 Presentación de resultados de regresión

# Presentación de resultados de regresión

- Ideas sobre como presentar los resultados y cómo se deben leer.
- Siempre hay que reportar los **estimadores MCO**. Para las variables clave hay que interpretar los coeficientes estimados (es una elasticidad? implicaciones económicas...)
- Siempre hay que acompañar los estimadores de los **errores estándar** (algunos autores prefieren reportar los estadísticos  $t$ ).
- Mejor los errores estándar:
  - Fuerza a pensar en la hipótesis nula, que no siempre es  $\beta_j = 0$ .
  - Permite calcular intervalos de confianza fácilmente.
- Siempre se incluye el **R<sup>2</sup>**: es una medida de bondad de ajuste y permite el contraste general.
- También el número de observaciones, **n**.
- Si se estiman sólo dos modelos se pueden presentar en forma de ecuación. Si se estiman más mejor presentar las estimaciones en una tabla.

# Presentación de resultados de regresión

Ejemplo: salarios y pensiones para maestros

Para explicar la compensación anual total para un maestro, que incluye salario y todos los beneficios (pensiones, seguro médico, etc.) se postula

$$\log(\text{totcomp}) = f(\text{productivity characteristics, other factor}).$$

Sin embargo:

$$\text{totcomp} = \text{salary} + \text{benefits} = \text{salary} \left( 1 + \frac{\text{benefits}}{\text{salary}} \right)$$

y entonces

$$\begin{aligned} \log(\text{totcomp}) &= \log(\text{salary}) + \log\left(1 + \frac{\text{benefits}}{\text{salary}}\right) \\ &\approx \log(\text{salary}) + \frac{\text{benefits}}{\text{salary}} \end{aligned}$$

# Presentación de resultados de regresión

Ejemplo: salarios y pensiones para maestros (2)

Esto lleva al modelo econométrico:

$$\log(\textit{salary}) = \beta_0 + \beta_1 (b/s) + \textit{other factors}$$

Para contrastar si hay un trade-off salario-beneficios se plantea:

$$H_0 : \beta_1 = -1, \quad H_1 : \beta_1 \neq -1$$

MEAP93: datos a nivel de colegio:

# Presentación de resultados de regresión

Ejemplo: salarios y pensiones para maestros (3)

Variable Dependiente: log ( <i>salary</i> )			
Variables Independientes	(1)	(2)	(3)
<i>b/s</i>	−,825 (,20)	−,605 (,16)	−,589 (,16)
log ( <i>enroll</i> )	-	,0874 (,0073)	0,0881 (,0073)
log ( <i>staff</i> )	-	−,222 (,050)	−,218 (,050)
<i>droprate</i>	-	-	−,00028 (,0016)
<i>gradrate</i>	-	-	,00097 (,00066)
<i>intercept</i>	10,523 (,042)	10,884 (,252)	10,738 (,258)
Observations	408	408	408
$R^2$	0.040	0.353	0.361