

INTRODUCCIÓN A LA ECONOMETRÍA

3er curso LE y LADE

Dpto. de Econometría y Estadística (EA3)

UPV—EHU

1 Introducción

1.1 Definiciones. Elementos de Econometría

Introducción: Definiciones

ECONOMETRÍA

- **etimológica:**

οίκος [oíkos], 'hogar',
y *νόμος* [nómos], 'reglas'

por lo tanto economía \rightsquigarrow 'administración doméstica',
+ *μετρώ* [metró], 'medir'.

Economía + Medición

- **aditiva:**

Ciencia social que aplica
Teoría económica, Matemática e Inferencia Estadística
en el análisis de fenómenos económicos (Goldberger(1964)).

- **utilitaria:** El arte del económetra = definir el modelo apropiado + encontrar el procedimiento estadístico óptimo

\rightsquigarrow económetra \neq estadístico;

... + sólida formación en Economía (Malinvaud(1963)).

Introducción: Definiciones

- **sencilla**: aplicación de métodos estadísticos a datos económicos (Maddala(1977)).
- **concisa**: determinación empírica de leyes económicas (Theil(1971)).
- AFG(2004): La econometría trata de
 - ◆ **formular** (o especificar),
 - ◆ **cuantificar** (o estimar),
 - ◆ **validar** (o contrastar),
relaciones entre variables económicas.

Introducción: 3 Elementos:

■ **TEORÍA ECONÓMICA:**

se encarga de

- ◆ (general:) análisis de la economía
- ◆ (específico:) **relaciones** entre variables económicas

■ **DATOS:**

cuantificar NO es uno de los objetivos de la T^a Económica

■ **ESTADÍSTICA:**

proporciona la estructura básica de **métodos de procesamiento de datos** para:

- ◆ **(estimar:)**
cuantificar relaciones entre variables de forma apropiada.
- ◆ **(contrastar:)**
validar resultados de acuerdo con ciertos estándares ya establecidos.

1.2 Concepto y ejemplo de modelo: Desde el modelo económico al modelo econométrico.

Elemento 1: T^a Económica: modelo básico

- ♦ **Caso:** gerente de empresa o director de ventas,
- ♦ **Interés:** saber la relación entre sus ventas y sus precios.
- ♦ **Lógica económica básica:** ventas como función del precio \rightsquigarrow modelo económico básico:

$$V_{\text{ventas}} = f\left(\underset{\text{precio}}{\underset{(-)}{p}}\right)$$

$f(\bullet)$ es una función genérica

(T^a Ec: $f(\bullet) = \text{fn inversa} \rightsquigarrow$ ventas \uparrow si precio \downarrow .)

Elemento 1: Tª Económica: vars adicionales

■ **Lógica económica adicional:**

ventas dependen de

- ◆ situación empresas rivales (p.ej. precio competencia)
- ◆ condiciones del mercado (p.ej. ciclo económico)

■ **Modelo completo:**

$$V_{\text{ventas}} = f\left(\underset{\text{precio}}{p}, \underset{\text{precio competencia}}{pc}, \underset{\text{ciclo}}{c} \right)$$

(-) (+) (+)

■ **NOTA:**

modelo económico propuesto \equiv **resumen de ideas**,
pero nada nuevo para el gerente;

él necesita **un modelo específico para su empresa**

\rightsquigarrow como sus ventas **responden** a **sus** precios.

Elemento 2: Datos:

- **Información específica:**

el gerente tiene **información** sobre:

- ♦ sus ventas y sus precios (**datos cuantitativos**)
 - ♦ precios de la competencia (**datos cuantitativos**)
 - ♦ momento cíclico (**datos cualitativos**)
- *p.ej.:*

fechas	Ventas	precios	p.comp	ciclo
ene 80	1725	12,37	11,23	alto
feb 80	1314	11,25	10,75	alto
abr 95	1234	13,57	14,5	bajo
⋮	⋮	⋮	⋮	⋮

y todo esto todos los meses hasta diciembre de 2004.

Elemento 2: Datos: modelo específico

- modelo específico para los datos existentes:

$$V_t = f(p_t, p_{c_t}, c_t), \quad t = 1980, 1, \dots, 2004, 12$$

donde el subíndice t indica el periodo o momento de la relación.

- hasta ahora:
 - ◆ **modelo económico**: resumen de ideas generales sobre la relación
 - ◆ **datos**: o información específica sobre las diferentes variables

 - ◆ ¿Cómo **poner juntos** estos elementos...????

E2: ¿modelo (genérico) + datos (especifico)?:

- **A:** supuestos sobre $f(\bullet)$; p.ej.: relaciones lineales.

El modelo será entonces:

$$V_t = \beta_0 + \beta_1 p_t + \beta_2 p c_t + \beta_3 c_t, \quad t = 1980,1, \dots, 2004,12$$

- $\beta \dots$ = parámetros o coeficientes :

p.ej. β_1 responde a la pregunta:

¿ en cuánto cambian las ventas si el precio cambia en una unidad monetaria ?

↪ políticas de precios, decisiones de producciones etc. para la empresa.

- **B:** indicadores:

asignar valores cuantitativos a variables cualitativas (como Ciclo): p.ej. sustituir por indicador tal como Índice de Producción Industrial.

E2: ¿Modelo + datos?: perturbaciones aleatorias

- Después de esto el modelo expresa una relación **cuantitativa** entre las variables:

$$1725 = \beta_0 + 12,37\beta_1 + 11,23\beta_2 + 101,7\beta_3 \quad (1980.\text{Ene})$$

$$1314 = \beta_0 + 11,25\beta_1 + 10,75\beta_2 + 97,3\beta_3 \quad (1980.\text{Feb})$$

$$\vdots = \vdots$$

- **NOTA:** ... ¿ diferente relación para cada mes ??? ...
- **C:** termino perturbación;
- volver al modelo *económico* genérico:
 - ⇒ comportamiento **estable** entre variables
 - ⇒ comportamiento **“promedio”** reflejado en los datos
 - ⇒ añadir **termino** u_t para cubrir pequeña discrepancias. . .

E2: ¿Modelo+datos?: interpretación

- El modelo **econométrico** será finalmente:

$$V_t = \beta_0 + \beta_1 p_t + \beta_2 p c_t + \beta_3 c_t + u_t$$

(“influencias” importantes y sistemáticas) (término de perturbación aleatoria)

- Interpretación de u_t :

- ⇒ efectos que afectan las ventas **ligeramente** en cada periodo pero no están reflejados explícitamente en el modelo.
- ⇒ pequeñas **discrepancias** en los datos.
- ⇒ efectos **no sistemáticos** \equiv más erráticos.
- ⇒ **variable aleatoria** con cierta ley de probabilidad (p.ej.: dn Normal).

Elemento 3: Estadística:

- Modelo contiene una **variable aleatoria**
 - ⇒ procedimientos **estadísticos** que garanticen buenos resultados:
- ⇒ **para estimar** valor numérico de los coeficientes,
- ⇒ **para contrastar** la validez de la relación,

- el modelo **estimado**
 - ◆ no será un modelo genérico
 - ◆ sino un modelo específico para la empresa
- ofrecerá al gerente
información específica para tomar decisiones.

1.3 El Modelo Econométrico. La Perturbación o término de Error.

Características Básicas: notación datos

Modelo econométrico más general con K variables:

- para datos de series temporales:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \cdots + \beta_K X_{Kt} + u_t, \quad t = 1, 2, \dots, T.$$

- o, para datos transversales (sección cruzada):

$$Y_i = \beta_0 + \beta_1 X_{1i} + \cdots + \beta_K X_{Ki} + u_i, \quad i = 1, 2, \dots, N.$$

- o, para datos de panel:

$$Y_{it} = \beta_0 + \beta_1 X_{1it} + \cdots + \beta_K X_{Kit} + u_{it}, \quad \begin{cases} i = 1, 2, \dots, N; \\ t = 1, 2, \dots, T. \end{cases}$$

Características Básicas: notación vars

- Y : la variable que queremos explicar:
v dependiente, v explicada, v endógena o regresando.
- $X_1, X_2 \dots X_K$: variables que explican la variable Y :
v explicativas, v independientes, v exógenas o regresores.
- $\beta_k, (k = 1 \dots K)$: constantes desconocidas que determinan la relación entre las variables:
parámetros o intercepto y coeficientes.
 $\hat{\beta}_k$ es el coeficiente estimado.
- u : variable que recoge otros efectos no importantes presentes en los datos:
perturbación aleatoria o término de error.

Diferencias Básicas con el modelo económico

Presencia de una **perturbación aleatoria** que

- refleja el comportamiento **errático**:

$$Y_t = \underbrace{\beta_0 + \beta_1 X_{1t} + \cdots + \beta_K X_{Kt}}_{\text{parte sistemática}} + \underbrace{u_t}_{\text{parte no sistemática o aleatoria}} \quad t = 1, 2, \dots, T.$$

- tiene **media cero**:

$$E(Y_t) = E(\beta_0 + \beta_1 X_{1t} + \cdots + \beta_K X_{Kt}) + \underbrace{E(u_t)}_{=0} \quad t = 1, 2, \dots, T.$$

- por lo tanto parte **sistemática** \equiv **media** comportamiento de Y .
- otros supuestos sobre u (hipótesis básica, etc.)
 - \rightsquigarrow comportamiento probabilístico en casos diferentes
 - \rightsquigarrow herramientas estadísticas \rightsquigarrow **Métodos Econométricos**.

Clasificación de modelos econométricos

Diferentes enfoques:

■ considerando los tipos de datos:

- ◆ modelos de **Series temporales**.
- ◆ modelos de **Sección cruzada**.

■ considerando el periodo de observación:

- ◆ **M estático**:: Vars medidas en el mismo momento.
- ◆ **M dinámico**:: Vars referidas a diferentes periodos:

$$p.ej. Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{1,t-1} + \beta_3 X_{2,t-1} + u_t$$

■ considerando el número de relaciones:

◆ **Modelos uniecuacionales**:

una única relación o ecuación.

◆ **Modelos de ecuaciones simultáneas**:

más de una ecuación.

etc.

1.4 Etapas en la elaboración del modelo. Utilidad del modelo.

Etapas en la elaboración del modelo

0. **Selección.** Resumir la teoría de interés:
 - elegir la variable a explicar: Y .
 - elegir la relación general: $Y = f(X)$.
1. **Especificación.** Esbozar modelo econométrico consistente con la teoría:
 - elegir las variables explicativas: $X_1 \dots X_K$.
 - elegir la forma funcional: *p.ej.* $f(\cdot) \equiv \text{lineal}$.
 - elegir el comportamiento probabilístico (distribución) de la perturbación aleatoria: u , *p.ej.* $u_t \sim \text{iid } \mathcal{N}(0, \sigma^2)$.

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_K X_K + u.$$

Etapas en la elaboración del modelo

2. **Estimación.** Cuantificar parámetros desconocidos de acuerdo con los datos existentes:

- encontrar datos para las variables:

$$Y_t, X_{1t}, \dots, \dots, X_{Kt} \quad \text{for } t = 1, \dots, T.$$

- elegir el método estadístico apropiado, *p.ej.* MCO:

$$Y_t = \hat{\beta}_0 + \hat{\beta}_1 X_{1t} + \dots + \hat{\beta}_K X_{Kt} + \hat{u}_t, \quad t = 1, 2, \dots, T.$$

3. **Validación.** Evaluar si el modelo representa correctamente el problema inicial:

- inferencia estadística sobre hipótesis.
- modelo no apto \rightsquigarrow volver a la fase de especificación.

Utilización del modelo econométrico

El modelo que haya pasado por todas la etapas previas puede entonces utilizarse para:

■ **análisis económico:**

- ◆ interpretación de coeficientes,
- ◆ contraste de hipótesis,
- ◆ etc.

■ **predicción:**

- ◆ **predicción series temporales:**

predecir valores futuros de Y .

- ◆ **en general:**

responder a preguntas del tipo

¿ qué pasaría si...?

2 El Modelo de Regresión Lineal (I). Especificación y Estimación.

2.1 Especificación del Modelo de Regresión Lineal General (MRLG).

Especificación del MRLG (1)

- **Objetivo:** Cuantificar la relación entre:
 - ◆ una variable Y y
 - ◆ un conjunto de K variables explicativas X_1, X_2, \dots, X_K ,
 - ◆ a través de un modelo lineal.
- **Punto de partida:**
 - ◆ un **modelo lineal** :
$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_K X_K + u,$$
 - ◆ una **muestra** de datos de **tamaño** T :
$$Y_t, X_{1t}, X_{2t}, \dots, X_{Kt}, t = 1 \dots T,$$
donde

$Y_t = t$ -ésima obs de Y ,

$X_{kt} = t$ -ésima obs de X_k , $k = 1, 2 \dots K$.

Especificación del MRLG (2)

■ MRLG:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \cdots + \beta_K X_{Kt} + u_t, \quad t = 1, 2, \dots, T,$$

cuyos **elementos** son (recuérdese):

- ◆ Y : variable dependiente ,
- ◆ $X_k, k = 1 \dots K$: variables explicativas ,
- ◆ β_0 : intercepto,
- ◆ $\beta_k, k = 1 \dots K$: coeficientes (parámetros a estimar),
- ◆ u : error o perturbación (aleatoria no observable),
que permite capturar:
 - variables no incluidas en el modelo,
 - comportamiento aleatorio de los agentes económicos,
 - errores de medición, etc.

MRLG en forma de observación

El modelo

$$Y_t = \beta_0 + \beta_1 X_{1t} + \cdots + \beta_K X_{Kt} + u_t, \quad t = 1, 2, \dots, T,$$

supone para cada observación:

$$Y_1 = \beta_0 + \beta_1 X_{11} + \beta_2 X_{21} + \cdots + \beta_K X_{K1} + u_1$$

$$Y_2 = \beta_0 + \beta_1 X_{12} + \beta_2 X_{22} + \cdots + \beta_K X_{K2} + u_2$$

.....

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \cdots + \beta_K X_{Kt} + u_t$$

.....

$$Y_T = \beta_0 + \beta_1 X_{1T} + \beta_2 X_{2T} + \cdots + \beta_K X_{KT} + u_T$$

MRLG en forma matricial (1)

o de otra manera en forma matricial:

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \dots \\ Y_t \\ \dots \\ Y_T \end{bmatrix} = \begin{bmatrix} \beta_0 + \beta_1 X_{11} + \beta_2 X_{21} + \dots + \beta_K X_{K1} \\ \beta_0 + \beta_1 X_{12} + \beta_2 X_{22} + \dots + \beta_K X_{K2} \\ \dots \\ \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \dots + \beta_K X_{Kt} \\ \dots \\ \beta_0 + \beta_1 X_{1T} + \beta_2 X_{2T} + \dots + \beta_K X_{KT} \end{bmatrix} + \begin{bmatrix} u_1 \\ u_2 \\ \dots \\ u_t \\ \dots \\ u_T \end{bmatrix}$$

MRLG en forma matricial (2)

■ es decir:

$$\begin{array}{c}
 \begin{bmatrix} Y_1 \\ Y_2 \\ \dots \\ Y_t \\ \dots \\ Y_T \\ Y \end{bmatrix} \\
 (T \times 1)
 \end{array}
 =
 \begin{array}{c}
 \begin{bmatrix} 1 & X_{11} & X_{21} & \dots & X_{K1} \\ 1 & X_{12} & X_{22} & \dots & X_{K2} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & X_{1t} & X_{2t} & \dots & X_{Kt} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & X_{1T} & X_{2T} & \dots & X_{KT} \end{bmatrix} \\
 X \\
 (T \times K+1)
 \end{array}
 \begin{array}{c}
 \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{pmatrix} \\
 \beta \\
 (K+1 \times 1)
 \end{array}
 +
 \begin{array}{c}
 \begin{bmatrix} u_1 \\ u_2 \\ \dots \\ u_t \\ \dots \\ u_T \\ u \end{bmatrix} \\
 (T \times 1)
 \end{array}$$

$$Y = X\beta + u.$$

↶

2.2 Supuestos Básicos (Clásicos) . Interpretación.

Supuestos Básicos del MRLG (1)

1. Supuestos sobre la relación:

- El modelo está **correctamente especificado**:

X_k explica $Y \Leftrightarrow X_k \in \text{modelo}$.

2. Supuestos sobre los parámetros:

- son **constantes** a lo largo de la muestra,
- aparecen **de forma lineal** (es decir una constante más coeficientes)

- ◆ $Y_t = \beta_0 + \beta_1 X_t + u_t$

- Nota: pero las vars Y, X_1, X_2, \dots pueden ser transformaciones:

- ◆ $Y_t = \beta_0 + \beta_1 X_t + \beta_2 X_t^2 + \beta_3 \frac{1}{X_t} + u_t$

- ◆ $Y_t = A X_{1t}^{\beta_1} X_{2t}^{\beta_2} e^{u_t}$ (¿ Por qué ?)

- ◆ ¿ y éste ? $Y_t = \beta_0 + \beta_1 \frac{1}{X_t - \beta_2} + u_t$

- ◆ ¿ y estos otros ? $\ln Y_t = \beta_0 X_t^{\beta_1} u_t; \quad Y_t = \beta_0 X_t^{\beta_1} + u_t$

- ◆ $Y_t = \beta_1 X_{1t} + \beta_2 X_{1t} X_{2t} + u_t; \quad Y_t = \beta_0 + \beta_1 X_{1t}^{X_{2t}} + u_t$

Supuestos Básicos del MRLG (2)

3. Supuestos sobre las variables explicativas:

a) X_1, \dots, X_K , son **cuantitativas y fijas** (es decir no aleatorias).

b) X_1, \dots, X_K , son **linealmente independientes**:

■ $\nexists X_k | X_k = \text{comb. lin. de otros (¿ por qué ?)}$

■ <2>Ejemplos de casos **no** válidos :

◆ $Y_t = \beta_0 + \beta_1 X_t + \beta_2 (2X_t + 3) + u_t$

◆ $Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 (X_{1t} + X_{2t}) + u_t$

■ <2>Ejemplos de casos válidos:

◆ $Y_t = \beta_0 + \beta_1 X_t + \beta_2 X_t^2 + u_t$

◆ $Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 X_{1t} X_{2t} + u_t$

Supuestos Básicos del MRLG (3)

4. Supuestos sobre el término de perturbación:

a) Media cero:

$$E(u_t) = 0 \quad \forall t \quad (\text{¿ no es obvio?}).$$

b) Homocedástico:

$$\text{Var}(u_t) = E(u_t^2) = \sigma_u^2 (= \sigma^2) \quad \text{const} (\forall t).$$

c) Serialmente incorrelacionado:

$$\text{Cov}(u_t, u_s) = E(u_t u_s) = 0 \quad \forall t \neq s.$$

d) Distribución normal^(*):

$$u_t \sim \mathcal{N} \quad \forall t.$$

(* añadido)

■ Supuestos 4a–4d conjuntamente:

$$u_t \sim \text{iid } \mathcal{N}(0, \sigma_u^2)$$

Supuestos Básicos en forma matricial (1)

- de 4a: **Vector de medias:**

$$\mathbf{E}(u) = \begin{bmatrix} \mathbf{E}(u_1) \\ \mathbf{E}(u_2) \\ \vdots \\ \mathbf{E}(u_T) \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} = 0_T$$

(T × 1)

- de 4b y 4c: **Matriz de Covarianzas:**

$$\mathbf{E}(uu') = \begin{bmatrix} \mathbf{E}(u_1^2) & \mathbf{E}(u_1u_2) & \dots & \mathbf{E}(u_1u_T) \\ \mathbf{E}(u_2u_1) & \mathbf{E}(u_2^2) & \dots & \mathbf{E}(u_2u_T) \\ \dots & \dots & \dots & \dots \\ \mathbf{E}(u_Tu_1) & \mathbf{E}(u_Tu_2) & \dots & \mathbf{E}(u_T^2) \end{bmatrix}$$

(T × T)

$$= \begin{bmatrix} \sigma_u^2 & 0 & \dots & 0 \\ 0 & \sigma_u^2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \sigma_u^2 \end{bmatrix} = \sigma_u^2 I_T$$

Supuestos Básicos en forma matricial (2)

- de manera más compacta:

$$u \sim \left(0, \sigma_u^2 I_T \right)$$

$(T \times 1)$ $(T \times 1)$ $(T \times T)$

- plus 4d:

$$u \sim \mathcal{N} \left(0, \sigma_u^2 I_T \right)$$

$(T \times 1)$ $(T \times 1)$ $(T \times T)$

2.3a Mínimos Cuadrados Ordinarios (MCO) en el Modelo de Regresión Lineal Simple (MRLS).

MRLS: la FRP

- Con $K = 1 \rightsquigarrow Y_t = \beta_0 + \beta_1 X_{1t} + u_t,$

$$\text{(MRLS): } Y_t = \alpha + \beta X_t + u_t. \quad (1)$$

- Función de Regresión Poblacional (FRP):

$$E(u_t) = 0 \rightsquigarrow \text{parte sistemática o FRP:}$$

$$E(Y_t) = \alpha + \beta X_t$$

- Interpretación de los parámetros:

◆ $\alpha = E(Y_t | X_t = 0)$: Valor esperado de Y_t
cuando la variable explicativa es cero.

◆ $\beta = \frac{\partial E(Y_t)}{\partial X_t} \simeq \frac{\Delta E(Y_t)}{\Delta X_t}$: Incremento en el valor (esperado) de Y_t
cuando $X \uparrow$ una unidad (c.p.).

- Objetivo: obtener estimaciones $\hat{\alpha}, \hat{\beta}$
de los parámetros desconocidos α, β en (1).

Función de Regresión Muestral (FRM)

- $\hat{\alpha}, \hat{\beta}$ \rightsquigarrow modelo estimado o FRM:

$$\hat{Y}_t = \hat{\alpha} + \hat{\beta}X_t$$

- Interpretación de las estimaciones:

- ◆ $\hat{\alpha} = (\hat{Y}_t | X_t = 0)$: Valor estimado de Y_t
cuando la variable explicativa es cero.

- ◆ $\hat{\beta} = \frac{\partial \hat{Y}_t}{\partial X_t} \simeq \frac{\Delta \hat{Y}_t}{\Delta X_t}$: Incremento estimado en Y_t
cuando $X \uparrow$ una unidad (c.p.).

- Nótese la diferencia: un estimador (una formula)
frente a una estimación (un número).

Perturbaciones frente a Residuos

- **Perturbaciones** en FRP:

$$u_t = Y_t - \mathbf{E}(Y_t) = Y_t - \alpha - \beta X_t$$

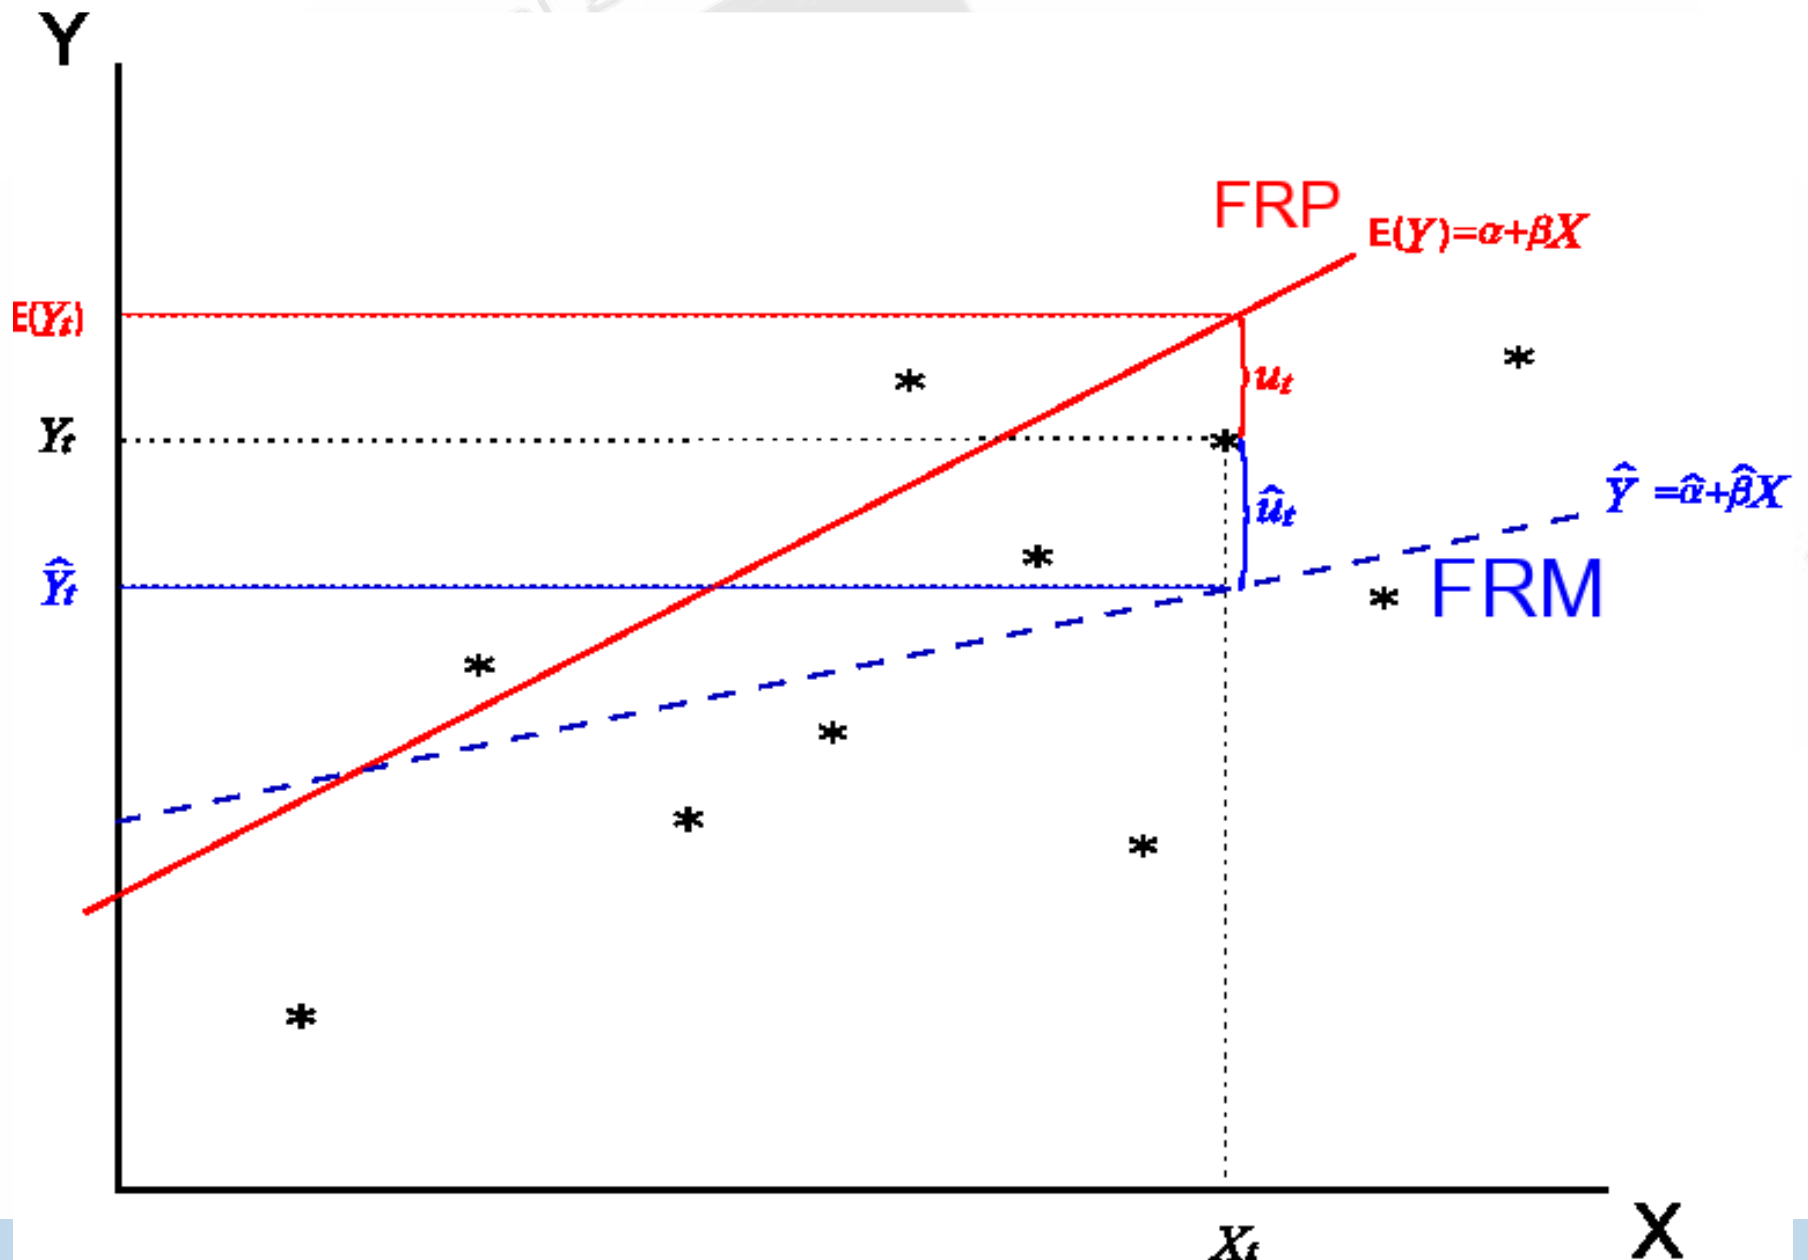
- **Residuos** en FRM:

$$\hat{u}_t = Y_t - \hat{Y}_t = Y_t - \hat{\alpha} - \hat{\beta} X_t$$

- Los **Residuos** son a la **FRM**

lo que las **perturbaciones** son a la **FRP**.

MRLS: FRP y FRM




Estimación: Propiedades Deseadas (1)

Sea $\hat{\beta}$ un estimador de β ...

Insesgadez:

$$E(\hat{\beta}) = \beta \Leftrightarrow \hat{\beta} \text{ insesgado}$$




Estimación: Propiedades Deseadas (2)

Sean $\hat{\beta}$ y $\tilde{\beta}$ dos estimadores insesgados de β ...

Eficiencia relativa:

$$\text{Var}(\hat{\beta}) \leq \text{Var}(\tilde{\beta}) \Leftrightarrow \hat{\beta} \text{ relativamente eficiente}$$



Estimación: criterio MCO

- $\langle 1 \rangle []$ MRLS: $Y_t = \alpha + \beta X_t + u_t$,
- aplicar ajuste **Mínimo-Cuadrático**:

$$\min_{\alpha, \beta} \sum_{t=1}^T u_t^2 \quad \text{donde} \quad u_t = Y_t - \alpha - \beta X_t :$$

- **Primeras derivadas:**

- ◆ $\frac{\partial \sum u_t^2}{\partial \alpha} = 2 \sum u_t \frac{\partial u_t}{\partial \alpha} = 2 \sum u_t (-1)$

- ◆ $\frac{\partial \sum u_t^2}{\partial \beta} = 2 \sum u_t \frac{\partial u_t}{\partial \beta} = 2 \sum u_t (-X_t)$

- **c.1^{er}o. (mínimo)** \Rightarrow primeras derivadas son cero:

- ◆ $\sum \hat{u}_t = \sum (Y_t - \hat{\alpha} - \hat{\beta} X_t) = 0$

- ◆ $\sum \hat{u}_t X_t = \sum (Y_t X_t - \hat{\alpha} X_t - \hat{\beta} X_t^2) = 0$

Estimación: Ecuaciones normales y EMC de α

- De las c.1^{er} o. anteriores:

$$\begin{aligned}\sum (Y_t - \hat{\alpha} - \hat{\beta}X_t) &= 0 \\ \sum (Y_tX_t - \hat{\alpha}X_t - \hat{\beta}X_t^2) &= 0\end{aligned}$$

- obtenemos las **Ecuaciones Normales**:

$$\left. \begin{aligned}\sum Y_t &= T\hat{\alpha} + \hat{\beta} \sum X_t \\ \sum Y_tX_t &= \hat{\alpha} \sum X_t + \hat{\beta} \sum X_t^2\end{aligned}\right\} \begin{array}{l} \text{¡ sistema de } 2 \\ \text{ecuaciones con } 2 \\ \text{incógnitas !!} \end{array}$$

- <1>Dividiendo la 1^a ec. normal por T :

$$\frac{1}{T} \sum Y_t = \frac{1}{T} T\hat{\alpha} + \hat{\beta} \frac{1}{T} \sum X_t$$

- Es decir:

$$\hat{\alpha}_{MCO} = \bar{Y} - \hat{\beta} \bar{X}$$

Estimación: Ecuaciones normales y EMC de β

- Sustituyendo $\hat{\alpha}$ en la 2ª ec. normal:

$$\sum Y_t X_t = (\bar{Y} - \hat{\beta} \bar{X}) \sum X_t + \hat{\beta} \sum X_t^2$$

- ... dividiendo por T y agrupando términos:

$$\frac{1}{T} \sum Y_t X_t = (\bar{Y} - \hat{\beta} \bar{X}) \frac{1}{T} \sum X_t + \hat{\beta} \frac{1}{T} \sum X_t^2$$

$$\frac{1}{T} \sum Y_t X_t - \bar{Y} \bar{X} = \hat{\beta} \left(\frac{1}{T} \sum X_t^2 - \bar{X}^2 \right)$$

- ... y despejando la incógnita:

$$\hat{\beta} = \frac{\frac{1}{T} \sum Y_t X_t - \bar{Y} \bar{X}}{\frac{1}{T} \sum X_t^2 - \bar{X}^2} = \frac{\frac{1}{T} \sum y_t x_t}{\frac{1}{T} \sum x_t^2} \left[\begin{array}{l} \text{¿ Por qué ?} \\ \text{? 'Por qué ?} \end{array} \right] \longrightarrow$$

- Es decir:

$$\hat{\beta}_{MCO} = \frac{\sum y_t x_t}{\sum x_t^2} = \frac{\text{Cov}(Y, X)}{\text{Var}(X)}$$

Recuérdese: ¿varianzas y covarianzas?

- ¿varianza de los datos originales (no centrados) ?

$$\begin{aligned}\text{Var}(X) &= \frac{1}{T} \sum x_t^2 = \frac{1}{T} \sum (X_t - \bar{X})^2 \\ &= \frac{1}{T} \sum X_t^2 + \frac{1}{T} \sum \bar{X}^2 - \frac{2}{T} \bar{X} \sum X_t\end{aligned}$$

$$\frac{1}{T} \sum x_t^2 = \frac{1}{T} \sum X_t^2 - \bar{X}^2$$

- ¿covarianza de los datos originales (no centrados) ?

$$\begin{aligned}\text{Cov}(Y, X) &= \frac{1}{T} \sum x_t y_t = \frac{1}{T} \sum (X_t - \bar{X})(Y_t - \bar{Y}) \\ &= \frac{1}{T} \sum X_t Y_t + \frac{1}{T} \sum \bar{X} \bar{Y} - \frac{1}{T} \bar{Y} \sum X_t - \frac{1}{T} \bar{X} \sum Y_t\end{aligned}$$

$$\frac{1}{T} \sum x_t y_t = \frac{1}{T} \sum X_t Y_t - \bar{X} \bar{Y}$$

Ejemplo numérico : datos de prod de fresas

- Datos...
- Datos centrados o “en desviaciones”
(desviaciones de las medias respectivas)...
- Cuadrados y productos...

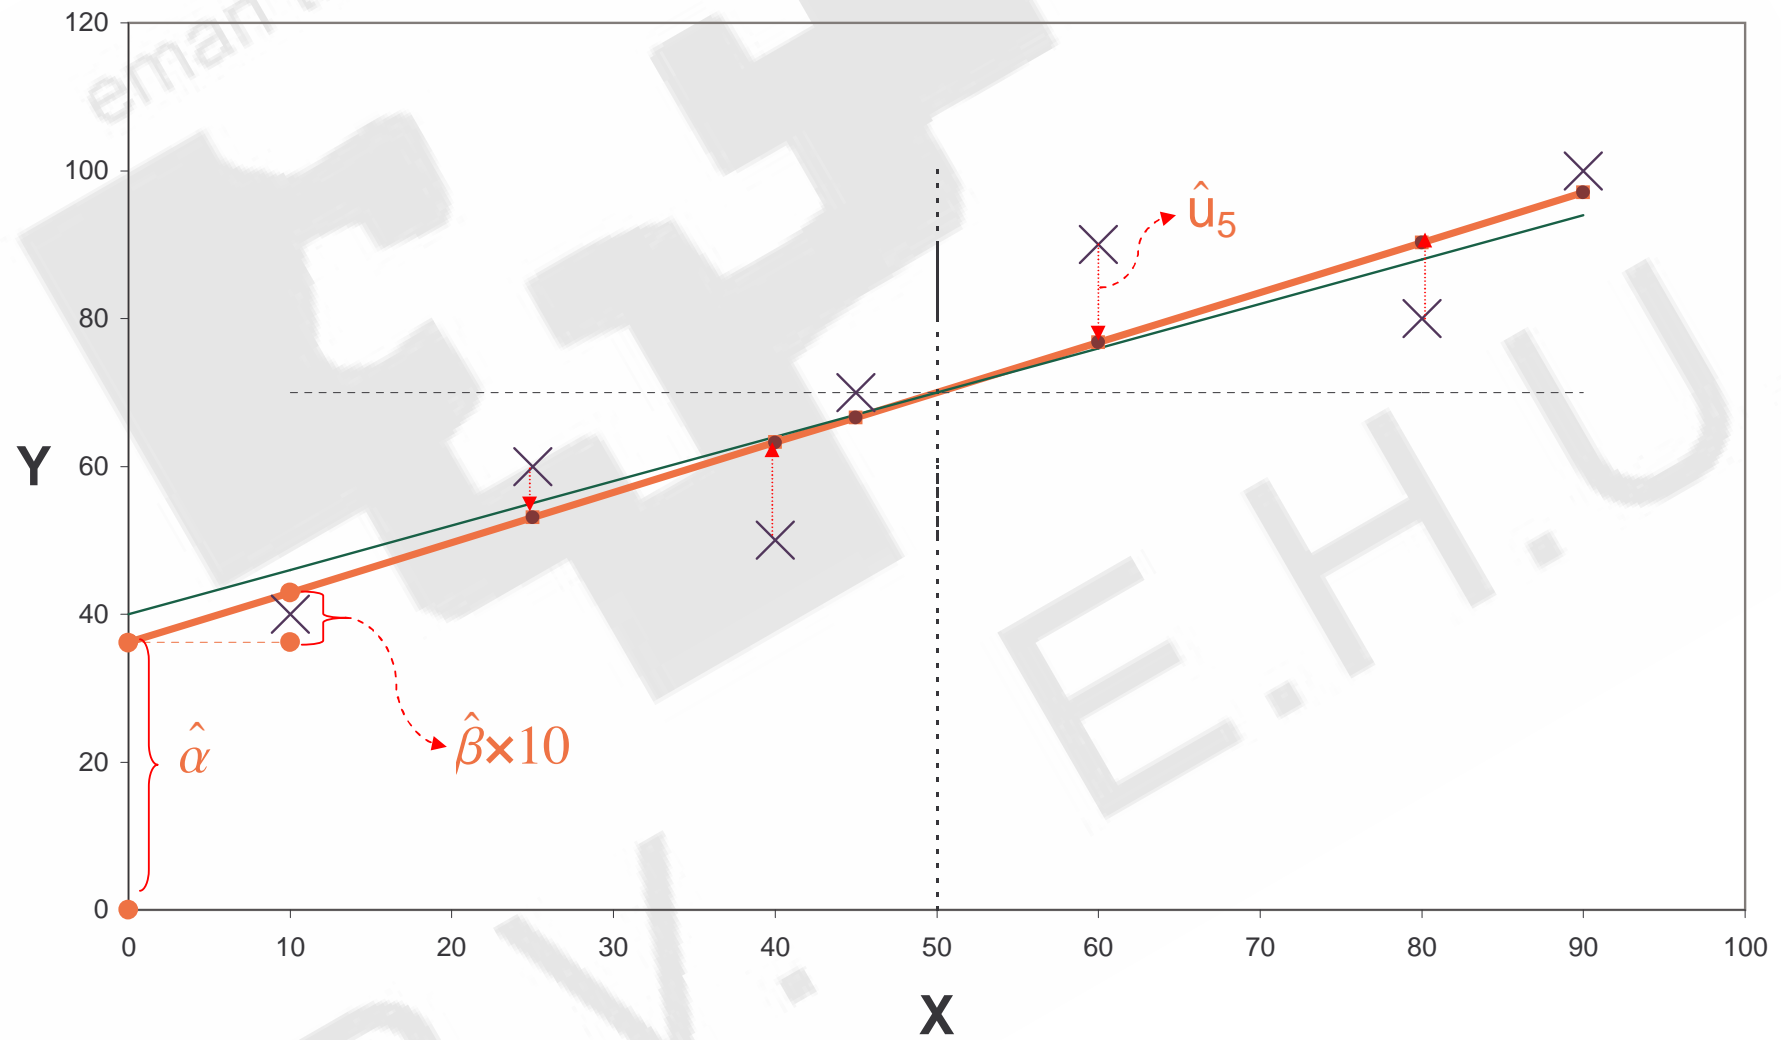
	Y	X	y	x	y^2	x^2	yx
	40	10	-30	-40	900	1600	1200
	60	25	-10	-25	100	625	250
	50	40	-20	-10	400	100	200
	70	45	0	-5	0	25	0
	90	60	20	10	400	100	200
	80	80	10	30	100	900	300
	100	90	30	40	900	1600	1200
Suma					2800	4950	3350
Media	70	50	0	0	400	707.14	478.57

$$\hat{\alpha} = 36,162 (= \bar{Y} - \hat{\beta}\bar{X})$$

$$\hat{\beta} = 0,677 \left(= \frac{\text{Cov}(Y, X)}{\text{Var}(X)} \right)$$

Se puede utilizar formulas basados en los datos originales... (Ejercicio: ¡ **Inténtalo** !)

Ejemplo numérico: gráfico regresión fresas



2.4a Propiedades de la Función de Regresión Muestral.

Propiedades de los residuos y la FRM (1)

$$\hat{\beta}_{\text{MCO}} \rightsquigarrow \hat{\alpha}_{\text{MCO}} \rightsquigarrow \hat{Y}_t = \hat{\alpha} + \hat{\beta}X_t \rightsquigarrow \hat{u}_t = Y_t - \hat{Y}_t$$

1. residuos suman cero: $\sum \hat{u}_t = 0$

Demo: directamente de las c.1^{er} o. □

2. $\overline{\hat{Y}} = \bar{Y}$

Demo: por def.: $\hat{u}_t = Y_t - \hat{Y}_t \rightsquigarrow \overline{\hat{Y}} = \bar{Y} - \overline{\hat{u}}$,

pero $\overline{\hat{u}} = \frac{1}{T} \sum \hat{u}_t = 0$ (de prop 1) $\rightsquigarrow \overline{\hat{Y}} = \bar{Y}$. □

3. la FRM pasa por el par de medias (\bar{X}, \bar{Y}) :

$$\bar{Y} = \hat{\alpha} + \hat{\beta}\bar{X}$$

Demo: de $\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X}$ (1^a ec. normal) □

Propiedades de los residuos y la FRM (2)

4. residuos ortogonales a v. expl. X : $\sum X_t \hat{u}_t = 0$


Demo: directamente de las c.1^{er} o. □

5. residuos ortogonales a la parte explicada de Y : $\sum \hat{Y}_t \hat{u}_t = 0$

Demo: $\sum (\hat{\alpha} + \hat{\beta} X_t) \hat{u}_t =$

$$\hat{\alpha} \underbrace{\sum \hat{u}_t}_{=0 \text{ (de prop 1)}} + \hat{\beta} \underbrace{\sum X_t \hat{u}_t}_{=0 \text{ (de prop 4)}} = 0$$
□

Causalidad: Y sobre X frente a X sobre Y



Propiedades de los residuos y FRM (5)

8. <3> $\hat{\alpha}_{\text{MCO}}$ y $\hat{\beta}_{\text{MCO}}$ **insesgados** \rightsquigarrow ¡ valor esperado = valor verdadero !

9. <2> [] **Demo:**



$$\hat{\beta} = \frac{\sum y_t x_t}{\sum x_t^2}$$

$$E(\hat{\beta}) = \frac{1}{\sum x_t^2} \sum \underbrace{E(y_t)}_{\beta x_t} x_t = \frac{1}{\sum x_t^2} \beta \sum x_t^2$$

$$E(\hat{\beta}) = \beta$$



$$\hat{\alpha} = \bar{Y} - \hat{\beta} \bar{X}$$

$$\begin{aligned} E(\hat{\alpha}) &= \frac{1}{T} \sum E(Y_t) - E(\hat{\beta}) \bar{X} \\ &= \frac{1}{T} \sum (\alpha + \beta X_t) - \beta \bar{X} = \alpha + \beta \bar{X} - \beta \bar{X} \end{aligned}$$

$$E(\hat{\alpha}) = \alpha$$



2.5a Bondad de Ajuste: Coeficiente de Determinación (R^2).

Bondad de Ajuste: Coeficiente de determinación

- Descomposición de la Suma de Cuadrados:

$$\begin{aligned}\sum Y_t^2 &= \sum (\hat{Y}_t^2 + \hat{u}_t^2 + 2\hat{Y}_t\hat{u}_t) \\ &= \sum \hat{Y}_t^2 + \sum \hat{u}_t^2 \quad (\text{de prop 5})\end{aligned}$$

- $\sum Y_t^2 - T\bar{Y}^2 = \sum \hat{Y}_t^2 - T\bar{\hat{Y}}^2 + \sum \hat{u}_t^2$ (de prop 2)

- $$\sum_{(SCT)} y_t^2 = \sum_{(SCE)} \hat{y}_t^2 + \sum_{(SCR)} \hat{u}_t^2$$

- Definición de R^2 :

$$R^2 = \frac{SCE}{SCT} = 1 - \frac{SCR}{SCT}$$

$0 \leq R^2 \leq 1$ (¿ Interpretación en términos de la varianza total ??)

No intercepto \rightsquigarrow inválido R^2

- $\langle 1 \rangle$ MRLS: $Y_t = \beta X_t + u_t$,
- aplicar el ajuste **Mínimo-Cuadrático**:

$$\min_{\beta} \sum_{t=1}^T u_t^2 \quad \text{donde} \quad u_t = Y_t - \beta X_t :$$

- **Primeras derivadas:**

$$\frac{\partial \sum u_t^2}{\partial \beta} = 2 \sum u_t \frac{\partial u_t}{\partial \beta} = 2 \sum u_t (-X_t)$$

- **c.1^{er}o. (mínimo)** \Rightarrow primera derivada = cero:

$$\sum \hat{u}_t X_t = \sum (Y_t X_t - \hat{\beta} X_t^2) = 0$$

-

¡ \nexists 1^a ecuación !! \rightsquigarrow $\begin{cases} \sum \hat{u}_t \neq 0, \\ \widehat{\bar{Y}} \neq \bar{Y}, \end{cases}$ \rightsquigarrow R^2 inválido (¿ Por qué ?)

Relación de R^2 con el coef de correlación

$$\begin{aligned} R^2 &= \frac{\frac{1}{T} \sum \hat{y}_t^2}{\frac{1}{T} \sum y_t^2} = \frac{\frac{1}{T} \sum (\hat{\beta} x_t)^2}{\frac{1}{T} \sum y_t^2} = \frac{\hat{\beta}^2 \frac{1}{T} \sum x_t^2}{\frac{1}{T} \sum y_t^2} \\ &= \hat{\beta}^2 \frac{\text{Var}(X)}{\text{Var}(Y)} = \frac{\text{Cov}(Y, X)^2 \text{Var}(X)}{\text{Var}(X)^2 \text{Var}(Y)} \\ &= \frac{\text{Cov}(Y, X)^2}{\text{Var}(X) \text{Var}(Y)} \end{aligned}$$

$$R^2 = r_{X,Y}^2$$

Ejemplo numérico: datos de prod fresas (cont)

- recuérdese datos y cálculos previos...
- hacer lo mismo para valores ajustados...
- ahora calcular R^2 ...

	y^2	\hat{Y}	\hat{y}	\hat{y}^2	\hat{u}	\hat{u}^2
	900	42.92	-27.07	732.82	-2.92	8.58
	100	53.08	-16.91	286.25	6.91	47.87
	400	63.23	-6.76	45.80	-13.23	175.09
	0	66.61	-3.38	11.45	3.38	11.45
	400	76.76	6.76	45.80	13.23	175.09
	100	90.30	20.30	412.21	-10.30	106.15
	900	97.07	27.07	732.82	2.92	8.58
Media	400	70	0	323.88		
Suma	2800			2267.17		532.82
	SCT			SCE		SCR

$$R^2 = 0,8097 \left(= \frac{SCE}{SCT} = 1 - \frac{SCR}{SCT} \right)$$

(Ejercicio: ¿ Cómo compara esto con $\text{Corr}(X, Y)$? ... **a' Inténtalo !!**)

2.3b MCO en el MRLG.

MRLG: la FRP

- Recuérdese: modelo con K variables explicativas :

$$Y_t = \beta_0 + \beta_1 X_{1t} + \cdots + \beta_K X_{Kt} + u_t,$$

$$Y = X\beta + u$$

(2)

se llama MRLG.

- Función de Regresión de Población (FRP):

$E(u) = 0 \rightsquigarrow$ *parte sistemática* o FRP:

$$E(Y_t) = \beta_0 + \beta_1 X_{1t} + \cdots + \beta_K X_{Kt}$$

$$E(Y) = X\beta$$

- Interpretación de los coeficientes:

- ◆ $\beta_0 = E(Y_t | X_{1t} = X_{2t} = \cdots = X_{Kt} = 0)$: Valor esperado de Y_t cuando todas las variables explicativas son iguales a cero.

- ◆ $\beta_k = \frac{\partial E(Y_t)}{\partial X_{kt}} \simeq \frac{\Delta E(Y_t)}{\Delta X_{kt}}, \quad k = 1 \dots K$: Incremento en el valor (esperado) Y_t cuando $X_k \uparrow$ una unidad (c.p.).

Función de Regresión Muestral (FRM)

- Objetivo del MRLG: obtener estimador $\hat{\beta} = (\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_K)'$ del vector de parámetros desconocidos en (2).

$\hat{\beta} \rightsquigarrow$ modelo estimado, ajuste o FRM:

$$\hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 X_{1t} + \dots + \hat{\beta}_K X_{Kt}$$

$$\hat{Y} = X\hat{\beta}$$

- Notas:
 - ◆ Perturbaciones en FRP:

$$u_t = Y_t - E(Y_t) = Y_t - \beta_0 - \beta_1 X_{1t} - \dots - \beta_K X_{Kt}$$

$$u = Y - E(Y) = Y - X\beta$$

- ◆ Residuos en FRM:

$$\hat{u}_t = Y_t - \hat{Y}_t = Y_t - \hat{\beta}_0 - \hat{\beta}_1 X_{1t} - \dots - \hat{\beta}_K X_{Kt}$$

$$\hat{u} = Y - \hat{Y} = Y - X\hat{\beta}$$

- Residuos son a la FRM lo que las perturbaciones a la FRP.

Estimación: MCO

- aplicar ajuste **Mínimo-Cuadrático** al MRLG: $Y = X\beta + u$,
- o bien en forma de observación:

$$\min_{\beta_0 \dots \beta_K} \sum_{t=1}^T u_t^2 \quad \text{donde } u_t = Y_t - \beta_0 - \beta_1 X_{1t} - \dots - \beta_K X_{Kt}$$

- o en forma matricial:

[recuérdese:

$$u' = (u_1, u_2, \dots, u_T)$$

$$u = \begin{pmatrix} u_1 \\ u_2 \\ \dots \\ u_T \end{pmatrix}$$

entonces $u'u = u_1^2 + u_2^2 + \dots + u_T^2 = \sum_{t=1}^T u_t^2$]

- es decir

$$\min_{\beta} u'u \quad \text{donde } u = Y - X\beta$$

Nota: derivadas vectoriales

- Sea $u = u(\beta)$: derivs de cu y cu^2 con respecto a β :

$$\frac{\partial}{\partial \beta}(cu) = c \frac{\partial u}{\partial \beta} \quad \text{y} \quad \frac{\partial}{\partial \beta} u^2 = 2u \frac{\partial u}{\partial \beta}$$

- Con vectores y matrices esto es bastante similar:

- La derivada de la combinación lineal $u'c$

$$\begin{matrix} u' & c \\ (1 \times n) & (n \times 1) \end{matrix} \quad \left(= \sum_{i=1}^n c_i u_i, \text{ es decir } \text{¡ escalar !!} \right)$$

con respecto a $\begin{matrix} \beta \\ (k \times 1) \end{matrix}$ es: $\frac{\partial(u'c)}{\partial \beta} = \frac{\partial u'}{\partial \beta} c$

- La derivada de la suma de cuadrados $u'u$

$$\begin{matrix} u' & u \\ (1 \times n) & (n \times 1) \end{matrix} \quad \left(= \sum_{i=1}^n u_i^2, \text{ es decir } \text{¡ escalar !!} \right)$$

con respecto a $\begin{matrix} \beta \\ (k \times 1) \end{matrix}$ es: $\frac{\partial(u'u)}{\partial \beta} = 2 \frac{\partial u'}{\partial \beta} u$

c.1^{er} o. en forma matricial

$$\min_{\beta} (u'u) \quad \text{donde} \quad u = Y - X\beta$$

Primera derivadas de SC $u'u$ con respecto a β :

$$\begin{aligned} \frac{\partial u'u}{\partial \beta} &= 2 \frac{\partial u'}{\partial \beta} u \\ &= 2 \frac{\partial (Y' - \beta' X')}{\partial \beta} u \\ &= -2 X' u \end{aligned}$$

en el mínimo:

$$\text{c.1}^{\text{er}} \text{ o. } X' \hat{u} = 0_{K+1}$$

$$(K+1 \times T) (T \times 1)$$

Estimación: Ecuaciones normales y EMC de β

Resolviendo las c.1^{er} o. obtenemos las **ecuaciones normales**:

$$X'(Y - X\hat{\beta}) = 0 \Rightarrow$$

$$\begin{array}{ccc} X'Y & = & X'X \hat{\beta} \\ (K+1 \times 1) & & (K+1 \times K+1) \quad (K+1 \times 1) \end{array}$$

(3)

De donde premultiplicando por $(X'X)^{-1}$ obtenemos el estimador MCO:

$$\hat{\beta}_{\text{MCO}} = (X'X)^{-1} X'Y$$

Estimación: EMC de β (cont)

- donde $X'X$ es una matriz $[K+1 \times K+1]$: [¿recuérdese X e Y ? \longrightarrow]

■

$$X'X \underset{(K+1 \times K+1)}{=} \begin{bmatrix} T & \sum X_{1t} & \sum X_{2t} & \dots & \sum X_{Kt} \\ \sum X_{1t} & \sum X_{1t}^2 & \sum X_{1t}X_{2t} & \dots & \sum X_{1t}X_{Kt} \\ \dots & \dots & \dots & \dots & \dots \\ \sum X_{Kt} & \sum X_{Kt}X_{1t} & \sum X_{Kt}X_{2t} & \dots & \sum X_{Kt}^2 \end{bmatrix}$$

- y $X'Y$ y $\hat{\beta}$ son vectores $[K+1 \times 1]$:

$$X'Y \underset{(K+1 \times 1)}{=} \begin{bmatrix} \sum Y_t \\ \sum X_{1t}Y_t \\ \dots \\ \sum X_{Kt}Y_t \end{bmatrix} \quad \hat{\beta} \underset{(K+1 \times 1)}{=} \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \dots \\ \hat{\beta}_K \end{bmatrix}$$

Estimador MCO con datos centrados

Una forma alternativa de obtener el estimador MCO es

$$\hat{\beta}_{\text{MCO}}^* = (x'x)^{-1}x'y$$

para los coeficientes del modelo.

... junto con el intercepto estimado obtenido de la primera ecuación normal

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

Nota: caso especial de $K = 1 \rightsquigarrow$ ¡ formulas idénticas a las del MRLS !!
(Demuéstralo).

2.4b Propiedades de la FRM.

Propiedades de los residuos y la FRM (1)

$$\left. \begin{array}{l} \hat{\beta} \\ \hat{\beta}^* \rightsquigarrow \hat{\beta}_0 \end{array} \right\} \rightsquigarrow \hat{Y} = X\hat{\beta} \rightsquigarrow \hat{u} = Y - \hat{Y}$$

1. residuos suman cero: $\sum \hat{u}_t = 0$

Demo: directamente de las c.1^{er} o.:

$$X'\hat{u} = 0 \Rightarrow \begin{bmatrix} \sum_1^T \hat{u}_t \\ \sum_1^T X_{1t}\hat{u}_t \\ \sum_1^T X_{2t}\hat{u}_t \\ \dots \\ \sum_1^T X_{Kt}\hat{u}_t \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \dots \\ 0 \end{bmatrix}$$

2. $\overline{\hat{Y}} = \overline{Y}$



3. la FRM pasa a través del vector $(\overline{X}_1, \dots, \overline{X}_K, \overline{Y})$:

$$\overline{Y} = \hat{\beta}_0 + \hat{\beta}_1 \overline{X}_1 + \dots + \hat{\beta}_K \overline{X}_K$$

Nota: Estas propiedades 1 a 3 son satisfechas si la regresión tiene **intercepto**; es decir, si X tiene una **columna de "unos"**.

Propiedades de los residuos y la FRM (2)

4. residuos ortogonales a v. explicativas: $X'\hat{u} = 0$

Demo: directamente de las c.1^{er} o. (ver 1) o, alternativamente:

$$\begin{aligned} X'\hat{u} &= X'(Y - X\hat{\beta}) = X'Y - X'X\hat{\beta} \\ &= X'Y - \underbrace{X'X(X'X)^{-1}X'Y}_{=I_{K+1}} = 0 \end{aligned}$$



5. residuos ortogonales a la parte explicada de Y : $\hat{Y}'\hat{u} = 0$

$$\textit{Demo: } \hat{Y}'\hat{u} = (X\hat{\beta})'\hat{u} = \hat{\beta}' \underbrace{X'\hat{u}}_{=0} = 0$$



2.5b Bondad de Ajuste: Coeficiente de Determinación (R^2) y Estimación de la Varianza del Error.

Bondad de Ajuste: R^2 (repaso)

Recuérdese (lo mismo que antes pero ahora lo hacemos con vectores):

$$\begin{aligned} Y'Y &= (\hat{Y}' + \hat{u}')(\hat{Y} + \hat{u}) \\ &= \hat{Y}'\hat{Y} + \hat{u}'\hat{u} + 2\hat{Y}'\hat{u} \\ &= \hat{Y}'\hat{Y} + \hat{u}'\hat{u} \quad (\text{desde prop 5}) \end{aligned}$$

$$Y'Y - T\bar{Y}^2 = \hat{Y}'\hat{Y} - T\bar{\hat{Y}}^2 + \hat{u}'\hat{u} \quad (\text{de prop 2})$$

$$\begin{array}{ccc} y'y & = & \hat{y}'\hat{y} + u'u \\ \downarrow & & \downarrow \quad \downarrow \\ (SCT) & & (SCE) \quad (SCR) \end{array}$$

$$R^2 = \frac{SCE}{SCT} = 1 - \frac{SCR}{SCT}$$

$$0 \leq R^2 \leq 1$$

Bondad de Ajuste: R^2 (repasso cont)

Nota 1: R^2 mide la **proporción** de la variación de la variable dependiente **explicada** por la variación de (una combinación lineal de) las variables explicativas.

Nota 2:

$$\text{no intercepto} \Rightarrow \begin{cases} \nexists 1^a \text{ fila de c.1}^{\text{er}} \text{ o.} \rightsquigarrow \begin{cases} \sum \hat{u}_t \neq 0, \\ \overline{\hat{Y}} \neq \bar{Y}, \end{cases} \\ \text{no válido } R^2 \text{ (¡ Recuérdese !)} \end{cases}$$

Estimación de $\text{Var}(u_t)$

$$\sigma^2 = \text{Var}(u_t) = \mathbf{E}(u_t^2) \simeq \frac{1}{T} \sum_{t=1}^T u_t^2$$

pero con residuos se tienen que satisfacer $K+1$ relaciones lineales en $X'\hat{u} = 0$ así que perdemos $K+1$ grados de libertad:

$$\hat{\sigma}^2 = \frac{1}{T-K-1} \sum_{t=1}^T \hat{u}_t^2$$

Por lo tanto proponemos el siguiente estimador:

$$\hat{\sigma}^2 = \frac{\text{RSS}}{T-K-1}$$

el cual claramente es un estimador **insesgado**:

Demo:

$$\mathbf{E}(\hat{\sigma}^2) = \frac{\mathbf{E}(\text{SCR})(*)}{T-K-1} = \frac{T-K-1}{T-K-1} = \sigma^2$$

□ (* ver libro de texto)

2.6 Propiedades del Estimador de Mínimos Cuadrados en muestras finitas. El Teorema de Gauss-Markov.

Propiedades del Estimador MCO (1)

El estimador $\hat{\beta}_{\text{MCO}} = (X'X)^{-1}X'Y$ tiene las siguientes propiedades:

- **Lineal:** $\hat{\beta}_{\text{MCO}}$ es una combinación lineal de perturbaciones:

$$\begin{aligned}\hat{\beta} &= (X'X)^{-1}X'(X\beta + u) \\ &= (X'X)^{-1}X'X\beta + (X'X)^{-1}X'u \\ &= \beta + (X'X)^{-1}X'u \\ &= \beta + \Gamma'u\end{aligned}$$

- **insesgado:** Dado queo $E(u) = 0$, $\hat{\beta}_{\text{MCO}}$ es insesgado:

$$\begin{aligned}E(\hat{\beta}) &= E(\beta + \Gamma'u) \\ &= \beta + \Gamma'E(u) \\ &= \beta\end{aligned}$$

Propiedades del Estimador MCO (2)

- **Varianza:** Recuérdese:

$$\text{Var}(u) = \sigma^2 I_T,$$

$$\hat{\beta} = \beta + (X'X)^{-1}X'u,$$

$$\begin{aligned}\text{Var}(\hat{\beta}) &= \mathbf{E}((\hat{\beta} - \beta)(\hat{\beta} - \beta)') \\ &= \mathbf{E}((X'X)^{-1}X'u u'X(X'X)^{-1}) \\ &= (X'X)^{-1}X' \mathbf{E}(uu') X(X'X)^{-1} \\ &= (X'X)^{-1}X' \sigma^2 I_T X(X'X)^{-1} \\ &= \sigma^2 (X'X)^{-1}X'X(X'X)^{-1}\end{aligned}$$

$$\text{Var}(\hat{\beta}) = \sigma^2 (X'X)^{-1}$$

Propiedades del Estimador MCO (2cont)

$$\text{Var}(\hat{\beta}) = \begin{bmatrix} \text{Var}(\hat{\beta}_0) & \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) & \dots & \text{Cov}(\hat{\beta}_0, \hat{\beta}_K) \\ \text{Cov}(\hat{\beta}_1, \hat{\beta}_0) & \text{Var}(\hat{\beta}_1) & \dots & \text{Cov}(\hat{\beta}_1, \hat{\beta}_K) \\ \dots & \dots & \dots & \dots \\ \text{Cov}(\hat{\beta}_K, \hat{\beta}_0) & \text{Cov}(\hat{\beta}_K, \hat{\beta}_1) & \dots & \text{Var}(\hat{\beta}_K) \end{bmatrix}$$

$$\sigma^2(X'X)^{-1} = \sigma^2 \begin{bmatrix} a_{00} & a_{01} & \dots & a_{0K} \\ a_{10} & a_{11} & \dots & a_{1K} \\ a_{20} & a_{21} & \dots & a_{2K} \\ \dots & \dots & \dots & \dots \\ a_{K0} & a_{K1} & a_{K2} & \dots & a_{KK} \end{bmatrix}$$

es decir a_{kk} es el $(k + 1, k + 1)$ -elemento del matriz $(X'X)^{-1}$:

$$\text{Var}(\hat{\beta}_k) = \sigma^2 a_{kk}$$

$$\text{Cov}(\hat{\beta}_k, \hat{\beta}_i) = \sigma^2 a_{ki}$$

Teorema Gauss-Markov

“Dados los supuestos básicos del MRLG, el estimador MCO es el de varianza mínima (el mejor) entre todos los estimadores lineales e insesgados”

$$\hat{\beta}_{\text{MCO}} = \mathbf{ELIO} = \mathbf{E}_{\text{estimador}} \mathbf{L}_{\text{ineal}} \mathbf{I}_{\text{nsesgado}} \mathbf{O}_{\text{ptimo}}$$

Demo:

Sea $\tilde{\beta}$ algún **otro** estimador lineal insesgado:

$$\tilde{\beta} = D'Y = D'(X\beta + u) = D'X\beta + D'u$$

$$\mathbf{E}(\tilde{\beta}) = D'X\beta + D'\mathbf{E}(u) = D'X\beta = \beta \Rightarrow \boxed{D'X = I_K}$$

entonces $\tilde{\beta} = \beta + D'u \rightsquigarrow \tilde{\beta} - \beta = D'u$

y su varianza:

$$\begin{aligned} \text{Var}(\tilde{\beta}) &= E \left[(\tilde{\beta} - \beta)(\tilde{\beta} - \beta)' \right] = \mathbf{E}(D'u u' D) \\ &= D' \mathbf{E}(uu') D = D' \sigma^2 I_T D = \sigma^2 D'D \end{aligned}$$

Teorema Gauss-Markov (cont)

$$\begin{aligned}\text{Var}(\tilde{\beta}) - \text{Var}(\hat{\beta}) &= \sigma^2 D' D - \sigma^2 (X' X)^{-1} \\ &= \sigma^2 [D' D - (X' X)^{-1}] \\ &= \sigma^2 [D' D - D' X (X' X)^{-1} X' D] \\ &= \sigma^2 D' \underbrace{[I_T - X (X' X)^{-1} X']}_M D \\ &= \sigma^2 D' (M M) D \\ &= \sigma^2 (D' M)(M' D) = D^{*'} D^* \\ &> 0\end{aligned}$$

Esto es, en particular **todas** las varianzas individuales serán mayores que las respectivas por MCO.

2.3c MCO: Expresiones útiles y Cronología.

Expresiones útiles para SC

- $$SCT = \sum (Y_t - \bar{Y})^2 = \sum Y_t^2 - T\bar{Y}^2 = Y'Y - T\bar{Y}^2$$

- $$\begin{aligned} SCE &= \sum (\hat{Y}_t - \bar{\hat{Y}})^2 = \sum \hat{Y}_t^2 - T\bar{\hat{Y}}^2 = \sum \hat{Y}_t^2 - T\bar{Y}^2 = \hat{Y}'\hat{Y} - T\bar{Y}^2 \\ &= (X\hat{\beta})'(X\hat{\beta}) - T\bar{Y}^2 = \hat{\beta}' \underbrace{X'X}_{X'Y} \hat{\beta} - T\bar{Y}^2 = \hat{\beta}' X'Y - T\bar{Y}^2 \end{aligned}$$

- $$SCR = \sum \hat{u}_t^2 = \hat{u}'\hat{u} = \sum Y_t^2 - \sum \hat{Y}_t^2 = Y'Y - \hat{\beta}' X'Y$$

Principales expresiones y Cronología

- $Y = X\beta + u$
- $(X'X)^{-1} X'Y$
- $\hat{\beta} = (X'X)^{-1} X'Y$
- $ESS = \hat{\beta}' X'Y - T\bar{Y}^2$ (¡ necesita \bar{Y} !)
- $TSS = Y'Y - T\bar{Y}^2$
- $RSS = Y'Y - \hat{\beta}' X'Y$ (¡ no \bar{Y} !)
- $R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS}$
- $\hat{\sigma}^2 = \frac{RSS}{T-K-1}$
- $\widehat{\text{Var}}(\hat{\beta}) = \hat{\sigma}^2 (X'X)^{-1}$

2.7a Omisión de variables relevantes.

Omisión de variables relevantes

■ **relación verdadera:**

$$Y = X\beta + u = \left[\begin{array}{c|ccc} X_I & & & \\ \hline & X_{II} & & \end{array} \right] \begin{pmatrix} \beta_I \\ \beta_{II} \end{pmatrix} + u$$

$$X = \left[\begin{array}{cccc|ccc} 1 & X_{11} & \cdots & X_{K_1,1} & X_{K_1+1,1} & \cdots & X_{K_1} \\ 1 & X_{12} & \cdots & X_{K_1,2} & X_{K_1+1,2} & \cdots & X_{K_2} \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ 1 & X_{1T} & \cdots & X_{K_1,T} & X_{K_1+1,T} & \cdots & X_{K_T} \end{array} \right], \beta = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_{K_1} \\ \hline \beta_{K_1+1} \\ \vdots \\ \beta_K \end{pmatrix}$$

$$Y = X_I\beta_I + X_{II}\beta_{II} + u$$

■ **relación estimada :**

$$Y = X_I\beta_I + v \quad \text{donde } v = X_{II}\beta_{II} + u,$$

$$\text{entonces } E(v) \neq 0 \quad \rightsquigarrow \quad E(\hat{\beta}) \neq \beta.$$

es decir $\hat{\beta}$ es **sesgado**.

Omisión de variables relevantes: consecuencias

Resumen:

- Estimador MCO de los **coeficientes** es **sesgado** (excepto si $x_I'x_{II} = 0$).
- Estimador MCO del **intercepto** es **siempre sesgado**.
- Estimador de **varianza del error** es **siempre sesgado**.

2.7b Multicolinealidad

Multicolinealidad Perfecta

Caso extremo:

■ combinación lineal **exacta**:

- ◆ $\sum_{k=0}^K \lambda_k X_{kt} = 0, \quad \lambda \neq 0, \quad X_{0t} = 1,$
- ◆ $\exists X_i \mid X_i = \lambda_0^* + \sum_{\substack{k=1 \\ k \neq i}}^K \lambda_k^* X_{kt},$
- ◆ $\exists X_i, X_j \mid \text{Corr}(X_i, X_j) = 1,$
- ◆ $\exists X_i \mid \text{regres aux } X_i \text{ sobre } \{X_k\}_{\substack{k=1 \\ k \neq i}}^K \rightsquigarrow R_i^2 = 1.$

■ Problema:

- ◆ $\text{rk } X < K+1, (X \text{ no es de rango completo})$
- ◆ $\rightsquigarrow \det(X) = 0$
- ◆ $\rightsquigarrow \nexists (X'X)^{-1}$
- ◆ \rightsquigarrow

¿ $\hat{\beta}$?

Multicolinealidad perfecta: ejemplo

- Sea $X_{4t} = 2X_{1t} \quad \forall t$:

$$X_{4t} = 0 + 2X_{1t} + 0 \cdot X_{2t} + 0 \cdot X_{3t} + 0 \cdot X_{5t} + \cdots + 0 \cdot X_{Kt},$$

- ¿no error? \Rightarrow regres aux X_4 sobre $\{X_k\}_{\substack{k=1 \\ k \neq 4}}^K \rightsquigarrow$ ¡ $R_4^2 = 1$!!

- Especificación del modelo:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \beta_4 X_{4t} + \cdots + u_t, t = 1, 2, \dots, T,$$

$$X_{4t} = 2X_{1t},$$

- y sustituyendo en el modelo:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \beta_4 (2X_{1t}) + \cdots + u_t,$$

$$= \beta_0 + \underbrace{(\beta_1 + 2\beta_4)}_{\beta_1^*} X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \cdots + u_t$$

- ahora tenemos **un parámetro menos** para estimar.

Multicolinealidad: contra-ejemplo

$$Y_t = \beta_0 + \beta_1^* X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \dots + u_t$$

- Sólo quedan K parámetros a estimar,
pero β_1 y β_4 **no se pueden estimar por separado**:
 - ◆ únicamente podemos estimar una combinación lineal de ellos:
$$\beta_1^* = \beta_1 + 2\beta_4,$$
 - ◆ *es decir* ¡ **efecto combinado** de X_{1t} y X_{4t} sobre Y_t !!

- (Ejercicio: **Pruébese con** $X_{2t} - 3X_{3t} = 10, \quad \forall t.$)

- multicolinealidad = *relaciones lineales*
pero... ¿ qué ocurre si **la relación no es lineal**? p.ej.:

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

- ◆ X tiene rango completo por columnas \rightsquigarrow **no hay problema.**

Multicolinealidad perfecta : consecuencias

- algunos parámetros no pueden estimarse **por separado**.
- algunas estimaciones son sólo **c.i. de los parámetros**.
- R^2 es **correcto**:
recoge correctamente la proporción de (la varianza de) Y_t explicada por la regresión.
- Las predicciones de Y son todavía **validas**.

2.7c Multicolinealidad imperfecta

Multicolinealidad imperfecta

- Problema:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \beta_4 X_{4t} + \dots + u_t, t = 1, 2, \dots, T,$$
$$X_{4t} = 2X_{1t} + v_t,$$

v_t = discrepancia entre X_{4t} y $2 X_{1t}$,

- relación **aproximada** :

- regresión auxiliar X_{4t} sobre el resto $\rightsquigarrow R^2 \approx 1$.
- es una cuestión de grado ($x'x$ no diagonal
 \rightsquigarrow variables correlacionadas)

- Nota: si no se especifica perfecta/imperfecta

quiere decir mc imperfecta.

Multicolinealidad: Síntomas

- Síntomas típicos :

- ◆ alto R^2

(grupo relevante de regresores)

- ◆ pero variables parecen **no relevantes** individualmente

(incapacidad de separar efectos de regresores).

- más formalmente:

$$\text{Var}(\hat{\beta}^*) = \sigma^2 (x'x)^{-1} = \frac{\sigma^2}{T} \text{Var}(X^*)^{-1}$$

$$\Rightarrow \text{Var}(\hat{\beta}_k) = \frac{\sigma^2}{T \text{Var}(X_k) (1 - R_k^2)},$$

- de forma que en el ejemplo anterior $X_{4t} \approx 2X_{1t}$:

- ◆ $\text{Corr}(X_4, X_1) \uparrow$

- ◆

R_4^2 y $R_1^2 \uparrow\uparrow$

- ◆

denominador \downarrow

- ◆

varianzas $\uparrow\uparrow$

Multicolinealidad: Consecuencias

- Algunos coeficientes **no son significativos**, a pesar de que sus variables tienen un efecto importante sobre la variable dependiente.
- De todas maneras, Gauss-Markov
⇒ estimadores lineales, **insesgados** y de **varianza mínima**,
entonces *no es posible encontrar un **ELI** (más) **Optimo**.*
- R^2 es **correcto**:
recoge correctamente la proporción de (la varianza de) Y_t
explicado por la regresión.
- Predicciones de Y son todavía **validas**.

Multicolinealidad: Como detectar

- **Pequeños cambios** en los datos
⇒ importantes **cambios** en las estimaciones
(pueden afectar hasta sus signos).
- Estimaciones de los **coeficientes**
no son significativas de forma **individual**...
- ... pero sí lo son de forma **conjunta**.
- **Alto** coeficiente de determinación R^2 .
- **Regresiones auxiliares** entre regresores
⇒ **alto** R_k^2 .

Multicolinealidad: Algunas soluciones

La multicolinealidad no es **un problema fácil** de solucionar.
De todas formas, de

$$\text{Var}(\hat{\beta}_k) = \frac{\sigma^2}{T \text{Var}(X_k)(1 - R_k^2)},$$

tenemos que para reducir la varianza podríamos:

T ↑: Incrementar el número de observaciones T .

También, las diferencias entre regresores pueden incrementar.

Var(X) ↑: Incrementar dispersión de los datos; *p.ej.* estudio sobre la función del consumo:

muestra de familias \leftrightarrow todas las rentas posibles.

Var(X) ↑: Incluir información adicional.

p.ej. imponer restricciones sugeridas por T^a . Ec.

σ^2 ↓: Añadir un nuevo regresor relevante todavía no incluido.

También evitaría serios problemas de sesgo.

R_k^2 ↓: Eliminar variables que pueden ser causa de la multicolinealidad.

(Aunque tener cuidado de no omitir algún regresor relevante).

2.8 Estimador MCO bajo Restricciones.

MRLG bajo restricciones lineales (1)

- objetivos de capítulos **previos**:
 - ◆ Modelo Econométrico (MRLG), características y supuestos básicos. . .
 - ◆ pero. . . **no hay conocimiento** sobre los parámetros del modelo.
 - ◆ El Método Mínimo-Cuadrático de estimación de parámetros (MCO).
 - ◆ Propiedades de los estimadores resultantes .
- objetivos del **presente** capítulo:
 - ◆ **Información a priori** sobre los valores del parámetro (o c.l.) . . .
 - ◆ dada por
 - teoría económica,
 - otros trabajos empíricos,
 - experiencia propia, etc.
 - ◆ Modelo No Restringido \Rightarrow MC Ordinarios.
 - ◆ Modelo Restringido \Rightarrow MC Restringidos.
 - ◆ **Comprobar**, dado el modelo estimado, si la información es compatible con los datos disponibles.

MRLG bajo restricciones lineales: ejemplos

- función de producción con rendimientos de escala constantes: $\beta_K + \beta_L = 1$.
- demanda del producto como función del precio: $\beta = -1$ (por ejemplo).
- en el MRLG: supongamos que $\beta_2 = 0$ y $2\beta_3 = \beta_4 - 1$:

- ◆ **Modelo completo:**

$$Y_t = \beta_0 + \beta_1 X_{1t} + \dots + \beta_{Kt} X_{Kt} + u_t, \text{ con } \beta_2 = 0 \text{ y } 2\beta_3 + 1 = \beta_4;$$

- ◆ **Modelo transformado** alternativo:

$$Y_t = \beta_0 + \beta_1 X_{1t} + 0X_{2t} + \beta_3 X_{3t} + (2\beta_3 + 1)X_{4t} + \dots + \beta_{Kt} X_{Kt} + u_t$$

$$Y_t - X_{4t} = \beta_0 + \beta_1 X_{1t} + \beta_3 (X_{3t} + 2X_{4t}) + \dots + \beta_K X_{Kt} + u_t$$

$$Y_t^* = \beta_0 + \beta_1 X_{1t} + \beta_3 Z_t + \dots + \beta_K X_{Kt} + u_t$$

donde $Y_t^* = Y_t - X_{4t}$ y $Z_t = X_{3t} + 2X_{4t}$.

- ◆ Este **modelo transformado**:

- se puede estimar por MCO:

$$\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_3, \hat{\beta}_5, \dots, \hat{\beta}_K, \text{ junto con } \hat{\beta}_2 = 0 \text{ y } \hat{\beta}_4 = 2\hat{\beta}_3 + 1.$$

- tiene nueva variable endógena Y_t^* (no siempre es así: p.ej. si $\beta_2 = 0$ sólo) y nueva variable explicativa Z_t .

MRLG bajo restricciones lineales (2)

- El método de “transformación” es bueno solamente para casos sencillos.
- En general, q restricciones lineales (no redundantes) entre parámetros:

$$\begin{matrix} 1 \\ \vdots \\ q \end{matrix} \begin{pmatrix} \diamond & \diamond & \diamond & \dots & \diamond \\ \vdots & & & & \\ \diamond & \diamond & \diamond & \dots & \diamond \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \dots \\ \beta_K \end{pmatrix} = \begin{pmatrix} \diamond \\ \vdots \\ \diamond \end{pmatrix}$$

- ◆ para una matriz R y vector r dados,

$$\begin{matrix} R & \beta = & r \\ (q \times K+1) & & (q \times 1) \end{matrix}$$

- ◆ <1>ejemplo de caso no valido (¿ por qué ?):

$$\beta_3 = 0, \quad 2\beta_2 + 3\beta_4 = 1, \quad \beta_1 - 2\beta_4 = 3, \quad 6\beta_4 = 2 - 4\beta_2 + \beta_3$$

MRLG bajo restricciones lineales (2cont)

- Escribir el ejemplo anterior $\beta_2 = 0$ y $2\beta_3 = \beta_4 - 1$ ($q = 2$ restricciones) como en la formula general:

$$\begin{matrix}
 \begin{pmatrix} 0 & 0 & 1 & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & 2 & -1 & 0 & \dots & 0 \end{pmatrix} & \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \dots \\ \beta_K \end{pmatrix} & = & \begin{pmatrix} 0 \\ -1 \end{pmatrix} . \\
 \begin{matrix} R \\ (2 \times K+1) \end{matrix} & \begin{matrix} \beta \\ (K+1 \times 1) \end{matrix} & & \begin{matrix} r \\ (2 \times 1) \end{matrix}
 \end{matrix}$$

- En general, escribimos el MRLG sujeto a q restricciones lineales como:

$$\begin{matrix}
 Y & = & X & \beta & + & u & , \\
 (T \times 1) & & (T \times K+1) & (K+1 \times 1) & & (T \times 1) & \\
 & & R & \beta & = & r & . \\
 & & (q \times K+1) & (K+1 \times 1) & & (q \times 1) &
 \end{matrix}$$

Estimación: MC Restringidos.

- Típico ejercicio de **optimización**:

$$\min_{\beta} (u'u) \quad \text{donde } u = Y - X\beta,$$

sujeto a $R\beta = r$.

- **Lagrangiano**:

$$L(\beta, \lambda) = u'u - 2\lambda'(R\beta - r)$$

$$\min_{\beta, \lambda} L(\beta, \lambda).$$

- **Primeras derivadas**:

$$\frac{\partial L(\beta, \lambda)}{\partial \beta} = -2X'u - 2R'\lambda,$$

$$\frac{\partial L(\beta, \lambda)}{\partial \lambda} = -2(R\beta - r),$$

Estimación: MC Restringidos (cont).

- c.1^{er}o. \rightsquigarrow **ecuaciones normales:**

$$X' \hat{u}_R + R' \hat{\lambda} = 0, \quad (4)$$

$$R \hat{\beta}_R = r, \quad (5)$$

donde $\hat{\beta}_R$ y $\hat{\lambda}$ son valores de β, λ que satisfacen las c.1^{er}o. y los residuos

$$\hat{u}_R = Y - X \hat{\beta}_R. \quad (6)$$

- **Despejando** $\hat{\beta}_R$ y $\hat{\lambda}$:

$$\hat{\lambda} = [R(X'X)^{-1}R']^{-1}(r - R\hat{\beta}),$$

$$\begin{aligned} \hat{\beta}_R &= \hat{\beta} + (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}(r - R\hat{\beta}) \\ &= \hat{\beta} + A(r - R\hat{\beta}) = (I - AR)\hat{\beta} + Ar \end{aligned} \quad (7)$$

donde $A = (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}$.

Estimación MCR: características

- Expresión (7): $\hat{\beta}_R = \hat{\beta} + A(r - R\hat{\beta}) \rightsquigarrow$
 - ◆ la estimación restringida $\hat{\beta}_R$ puede obtenerse como una función de la estimación ordinaria (no restringida): $\hat{\beta}$
 - ◆ $R\hat{\beta} \simeq r \Rightarrow \hat{\beta}_R$ (restringido) $\simeq \hat{\beta}$ (no restringido) .
- <2>Ecuaciones normales (4): $X' \hat{u}_R + R' \hat{\lambda} = 0 \rightsquigarrow$
 - ◆ se satisfacen las restricciones (obvio).
 - ◆ $X' \hat{u}_R \neq 0$, es decir:
 - suma de residuos restringidos no es cero,
 - residuos restringidos no ortogonales a las variables explicativas,
 - entonces, residuos restringidos no ortogonales a \hat{Y}_R ajustado.
 - ◆ **SCT \neq SCR_R + SCE_R**
(compárese con caso ordinario y con ecuación transformada: ¿ R^2 ??).

Propiedades del estimador MCR (1)

Expresión (7) : $\hat{\beta}_R = (I - AR) \hat{\beta} + Ar \rightsquigarrow$

1. **Lineal:** estimador MCR $\hat{\beta}_R$ es c.l. del estimador MCO $\hat{\beta}$, que es lineal, luego, a su vez, $\hat{\beta}_R$ es también lineal

2. **Sesgo:** estimador MCR $\hat{\beta}_R$ es $\begin{cases} \text{sesgado,} & \text{si } R\beta \neq r, \\ \text{insesgado,} & \text{si } R\beta = r \text{ cierto} \end{cases}$

Demo:

$$E(\hat{\beta}_R) = (I - AR) E(\hat{\beta}) + Ar = (I - AR) \beta + Ar = \beta + A(r - R\beta).$$

3. **Matriz de Covarianzas:** $\text{Var}(\hat{\beta}_R) = (I - AR) \text{Var}(\hat{\beta}) = \sigma^2 (I - AR)(X'X)^{-1}$

Demo: (ver apuntes o libro de texto)

Propiedades del estimador MCR (2)

4. **Varianza menor** que los estimadores MCO,
*aunque las restricciones **no sean ciertas**:*

Demo:

$$\begin{aligned}\text{Var}(\hat{\beta}_R) &= \text{Var}(\hat{\beta}) - AR \text{Var}(\hat{\beta}) \\ &= \text{Var}(\hat{\beta}) - (\text{matriz psd}).\end{aligned}$$



5. resultado sorprendente (aparentemente):
- menos “incertidumbre” sobre parámetros
 \rightsquigarrow más precisión en estimación. . .
 - pero. . . hacía un resultado erróneo (sesgado)
 si la restricción no es cierta.

Multicolinealidad frente a restricciones

Es importante **distinguir claramente** entre dos casos diferentes:

- relaciones lineales **entre regresores** (es decir multicolinealidad):

$$\text{p.ej. } X_{4t} = 2X_{1t}$$

⇒ falta información para estimaciones individuales.

- relaciones lineales **entre coeficientes**:

$$\text{p.ej. } \beta_4 = 2\beta_1$$

⇒ información extra sobre parámetros

↪ estimadores con varianza más pequeña.

- modelos a estimar respectivamente:

$$Y_t = \beta_0 + \underbrace{(\beta_1 + 2\beta_4)}_{\beta_1^*} X_{1t} + \beta_2 X_{2t} + \dots + u_t,$$

⇒ $\hat{\beta}_1^*$ pero ¿ $\hat{\beta}_1, \hat{\beta}_4$?

$$Y_t = \beta_0 + \beta_1 \underbrace{(X_{1t} + 2X_{4t})}_{X_{1t}^*} + \beta_2 X_{2t} + \dots + u_t,$$

⇒ $\hat{\beta}_1$ y $\hat{\beta}_4 = 2\hat{\beta}_1$

3 El Modelo de Regresión Lineal (II). Inferencia y Predicción.

3.1a Distribución del Estimador de Mínimo Cuadrados bajo el supuesto de Normalidad.

Estimador MCO bajo Normalidad

- Si $Y = X\beta + u$, donde $u \sim \mathcal{N}(0, \sigma^2 I_T)$, entonces (recuérdese) el estimador MCO:

$$\begin{aligned}\hat{\beta}_{\text{MCO}} &= (X'X)^{-1}X'Y = \beta + (X'X)^{-1}X'u \\ &= \beta + \Gamma'u \quad \text{es lineal en perturbaciones.}\end{aligned}$$

- Por lo tanto, la misma distribución **Multivariante Normal**, con (recuérdese)

$$\begin{cases} \mathbf{E}(\hat{\beta}) &= \beta, \\ \text{Var}(\hat{\beta}) &= \sigma^2 (X'X)^{-1}. \end{cases}$$

- Es decir:

$$\hat{\beta} \sim \mathcal{N}(\beta, \sigma^2 (X'X)^{-1})$$

Estimador MCO bajo Normalidad (casos)

Dado que $\hat{\beta} \sim \mathcal{N}(\beta, \sigma^2 (X'X)^{-1})$:

- Para el k -ésimo coeficiente:

$$\hat{\beta}_k \sim \mathcal{N}(\beta_k, \sigma^2 a_{kk})$$

donde a_{kk} es el $(k + 1)$ -ésimo elemento diagonal de $(X'X)^{-1}$

- *por ejemplo:* $\hat{\beta}_1 \sim \mathcal{N}(\beta_1, \sigma^2 a_{11})$,

$a_{11} = 2^{\circ}$ elemento diagonal.

- Para un conjunto de combinaciones lineales:

$$R\hat{\beta} \sim \mathcal{N}(R\beta, \sigma^2 R(X'X)^{-1}R').$$

- Para un subvector de $\hat{\beta}$: $R = [0_s \dots 0_s | I_s]$; entonces

$$\hat{\beta}^s \sim \mathcal{N}(\beta^s, \sigma^2 A_{ss})$$

donde $\beta^s =$ subvector de β , $A_{ss} =$ submatriz de $(X'X)^{-1}$.

Estimador MCO bajo Normalidad (casos)2

- En particular, si $R = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \Rightarrow$

$$R \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \end{pmatrix} = \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix} = \beta^* \text{ (sin intercepto):}$$

- y

$$(X'X)^{-1} = \begin{pmatrix} a_{00} & a_{01} & a_{02} \\ a_{10} & a_{11} & a_{12} \\ a_{20} & a_{21} & a_{22} \end{pmatrix};$$

- entonces

$$\hat{\beta}^* \sim \mathcal{N}(\beta^*, \sigma^2 \diamond)$$

Residuos MCO bajo Normalidad

- De forma similar, si $u \sim \mathcal{N}(0, \sigma^2 I_T)$,

Entonces,

$$\hat{u} \sim \mathcal{N}(0, \sigma^2 M)$$

- En particular, para el 4º residuo:

$$\hat{u}_t \sim \mathcal{N}(0, \sigma^2 m_{44})$$

donde m_{44} es el 4º elemento diagonal de la matriz M .

3.1b Contrastar Hipótesis: un Repaso.

Hipótesis y Contrastes (rep1)

- Punto de partida:

$$\left. \begin{array}{l} Y = X\beta + u \\ u \sim \mathcal{N}(0, \sigma^2 I_T) \end{array} \right\} \left\{ \begin{array}{l} \hat{\beta} \sim \mathcal{N}(\beta, \sigma^2 (X'X)^{-1}) \\ \hat{u} \sim \mathcal{N}(0, \sigma^2 M) \end{array} \right.$$

- **Hipótesis:** “conjetura sobre la fn de dn de(l) parámetro(s)”.

Por ejemplo:

- ◆ en MRLS: $\hat{\beta} \sim \mathcal{N}(\beta, v)$; sea $\beta = 2,5$.
- ◆ en MRLG: $\hat{\beta} \sim \mathcal{N}(\beta, \sigma^2 (X'X)^{-1})$; sea $\beta_1 + \dots + \beta_K = 1$.
- ◆ en general: T^a Ec. \rightsquigarrow hipótesis
p.ej.: Fn Cobb-Couglas:

$$Y_t = e^{\beta_0} L_t^{\beta_1} K_t^{\beta_2} e^{u_t}$$

con rendimientos de escala constantes : $\beta_1 + \beta_2 = 1$

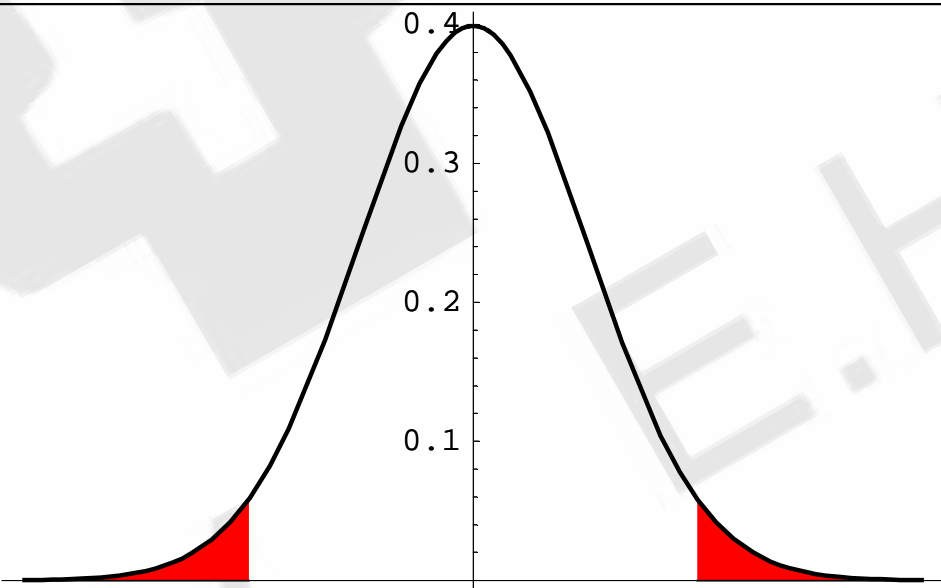
- **Contraste:** “procedimiento para **rechazar** o **aceptar** la hipótesis”

Hipótesis y Contrastes (rep2)

	elementos	pasos
a)	hipótesis para contrastar (sobre estimador)	$H_0 : \dots$ frente a $H_a : \dots$ (disjunta)
b)	dn estimador	obtener estadístico de contraste con dn tabulada bajo H_0 :
c)	regla decisión	<p style="text-align: center;">estadístico calculado</p> <div style="display: flex; justify-content: space-around; align-items: center;"> <div style="text-align: center;"> <p>\in región crítica ("grande")</p> <p>⇓</p> <p>Rechazar</p> </div> <div style="text-align: center;"> <p>\notin región crítica ("pequeño")</p> <p>⇓</p> <p>no Rechazar</p> </div> </div>


Hipótesis y Contrastes (rep2-cont)

Ejemplo:

a)	$H_0 : \beta = 2,5$ frente a $H_a : \beta \neq 2,5$	$(\text{Var}(\beta)=4)$
b)	$\hat{\beta} \sim \mathcal{N}(\beta, 4) \rightsquigarrow z = \frac{\hat{\beta} - \beta}{2} \sim \mathcal{N}(0, 1)$	
c)	$z = \frac{\hat{\beta} - 2,5}{2} \in$ 	

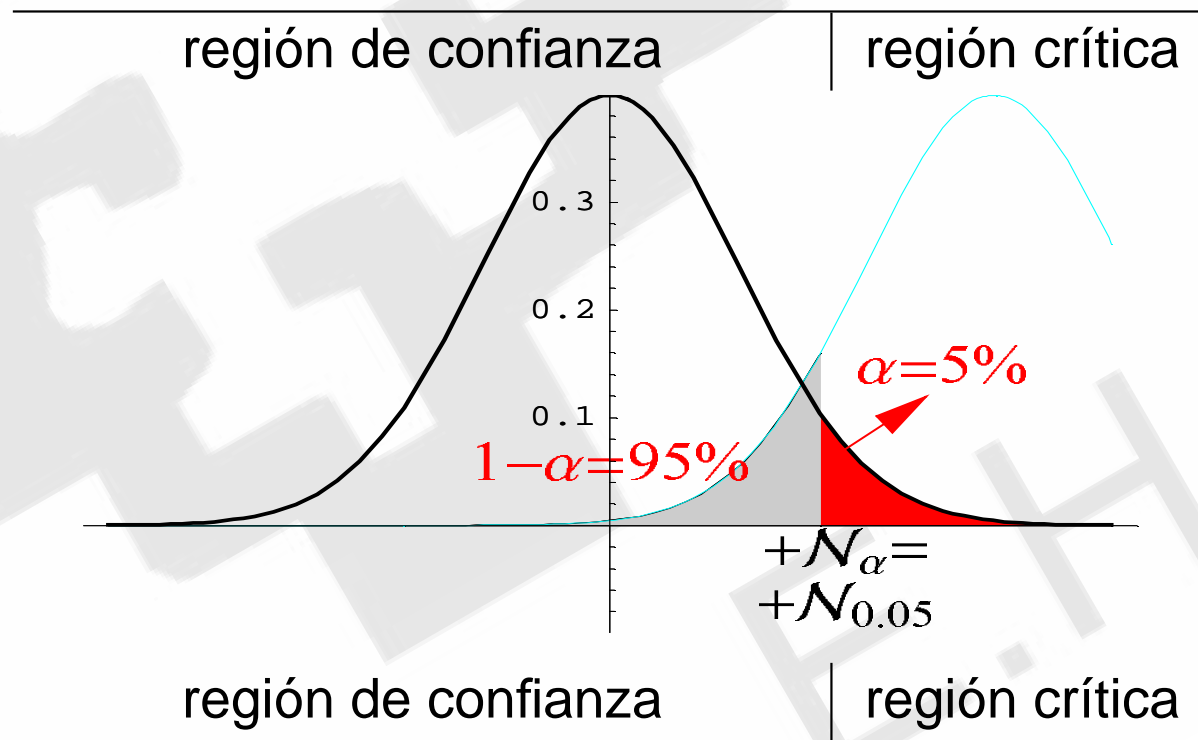
Hipótesis y Contrastes: Región Crítica

nivel de significación $\alpha = 5\% = 0,05$



Hipótesis y Contrastes: Región crítica (una cola)

nivel de significación $\alpha = 5\% = 0,05$



Hipótesis y Contrastes: Distribuciones (repaso)

1. Def de χ^2 (ji-cuadrado):

$$\left. \begin{array}{l} Z_i \sim \text{iid } \mathcal{N}(0, 1) \\ Z \sim \mathcal{N}(0, I_m) \end{array} \right\} Z'Z = \sum_{i=1}^m Z_i^2 \sim \chi^2(m) \quad \left\{ \begin{array}{l} \mathbb{E}(\chi^2(m)) = m \\ \text{Var}(\chi^2(m)) = 2m \end{array} \right.$$

1b. $Z \sim \mathcal{N}(\mu, \Omega) \Rightarrow (Z - \mu)' \Omega^{-1} (Z - \mu) \sim \chi^2(m)$

2. Def de t (Student): $\left. \begin{array}{l} Z \sim \mathcal{N}(0, 1), \quad W \sim \chi^2(m) \\ Z, W \text{ independientes} \end{array} \right\} \frac{Z}{\sqrt{W/m}} \sim t(m)$

3. Def de \mathcal{F} (Snedecor): $\left. \begin{array}{l} V \sim \chi^2(n) \quad W \sim \chi^2(m) \\ V, W \text{ independientes} \end{array} \right\} \frac{V/n}{W/m} \sim \mathcal{F}_m^n$

4b. $n = 1 \Rightarrow \frac{Z^2}{W/m} \sim \mathcal{F}_m^1 \equiv t(m)^2$

Hipótesis y Contrastes: Resultado útil

De $\hat{u} \sim \mathcal{N}(0, \sigma^2 M)$:

■ $\frac{SCR}{\sigma^2} = \sum (\hat{u}_t^2 / \sigma^2) = \sum \mathcal{N}(0, 1)^2\text{'s} \sim \chi^2(T-K-1)$

■ Entonces: $\frac{\hat{\sigma}^2}{\sigma^2} = \frac{SCR}{\sigma^2(T-K-1)} = \frac{SCR}{\sigma^2(T-K-1)} = \chi^2/\text{d.f.'s}$

◆ $\frac{\text{expr}}{\sigma} \sim \mathcal{N}(0, 1)$:

◆ $\frac{\text{expr}}{\hat{\sigma}} = \frac{\text{expr}/\sigma}{\hat{\sigma}/\sigma} = \frac{\text{expr}/\sigma}{\sqrt{\hat{\sigma}^2/\sigma^2}} = \frac{\mathcal{N}(0, 1)}{\sqrt{\chi^2/\text{d.f.'s}}} = t$

◆ $\frac{\text{expr}}{\sigma^2} \sim \chi^2(n)$:

◆ $\frac{\text{expr}}{\hat{\sigma}^2} = \frac{\text{expr}/\sigma^2}{\hat{\sigma}^2/\sigma^2} \Rightarrow \frac{\frac{\text{expr}}{\sigma^2}/n}{\hat{\sigma}^2/\sigma^2} = \frac{\chi^2(n)/n}{\chi^2/\text{d.f.'s}} \sim \mathcal{F}$

■ En resumen: $\sigma^2 \rightarrow \hat{\sigma}^2 \Rightarrow$
 i $\mathcal{N}(0, 1) \rightarrow t$!!
 i $\chi^2 \rightarrow \mathcal{F}$!!

3.2a Contraste para Significación de un único parámetro. Intervalos de Confianza.

Contraste de Signif de un parámetro: dn

- Estandarizar $\hat{\beta}_i \sim \mathcal{N}(\beta_i, \sigma^2 a_{ii})$

$$\frac{\hat{\beta}_i - \beta_i}{\sqrt{\text{Var}(\hat{\beta}_i)}} = \frac{\hat{\beta}_i - \beta_i}{\sigma \sqrt{a_{ii}}} = \frac{\hat{\beta}_i - \beta_i}{\sigma_{\hat{\beta}_i}} \sim \mathcal{N}(0, 1)$$

- cambiar σ por $\hat{\sigma}$:

$$\frac{\hat{\beta}_i - \beta_i}{\hat{\sigma} \sqrt{a_{ii}}} = \frac{\hat{\beta}_i - \beta_i}{\sqrt{\widehat{\text{Var}}(\hat{\beta}_i)}} = \frac{\hat{\beta}_i - \beta_i}{S_{\hat{\beta}_i}} \sim \mathbf{t}(T-K-1)$$

- Nota: $\sigma_{\hat{\beta}_i} \rightarrow S_{\hat{\beta}_i} \Rightarrow \mathbf{i} \mathcal{N}(0, 1) \rightarrow \mathbf{t} !!$

Contraste de Signif de un parámetro: regla


- $$\frac{\hat{\beta}_i - \beta_i}{S_{\hat{\beta}_i}} \sim t(T-K-1)$$
- ¿ Qué Contraste ? $\begin{cases} H_0 : \beta_i = c & \text{(contraste informativo)} \\ H_0 : \beta_i = 0 & \text{(contraste de significatividad)} \end{cases}$
- **Recuérdese:** Hipótesis \rightsquigarrow estadístico \rightsquigarrow regla...
- Contraste de Significatividad:
 - ◆ **Hipótesis:** $H_0 : \beta_i = 0$ frente a $H_a : \beta_i \neq 0$
 - ◆ **Estadístico:** $t = \frac{\hat{\beta}_i}{S_{\hat{\beta}_i}} \sim t(T-K-1)$ bajo H_0 :
 - ◆ **Regla:** $|t| = \left| \frac{\hat{\beta}_i}{S_{\hat{\beta}_i}} \right| > t_{\alpha/2}(T-K-1) \Rightarrow$ rechazar H_0 :
 - $\Rightarrow \beta_i$ es (estadísticamente o significativamente) distinto de cero
 - $\Rightarrow X_i$ es una variable (estadísticamente) relevante o significativa.
- de forma similar para el contraste informativo $H_0 : \beta_i = c$ (Ejercicio: ¡ Inténtalo !!)

Contraste de Signif de un parámetro: regla (cont

- Regla: $|t| = \left| \frac{\hat{\beta}_i}{S_{\hat{\beta}_i}} \right| > t_{\alpha/2}(T-K-1) \Rightarrow$ rechazar H_0 :

nivel de significación $\alpha = 5\% = 0,05$

región crítica | región de confianza | región crítica



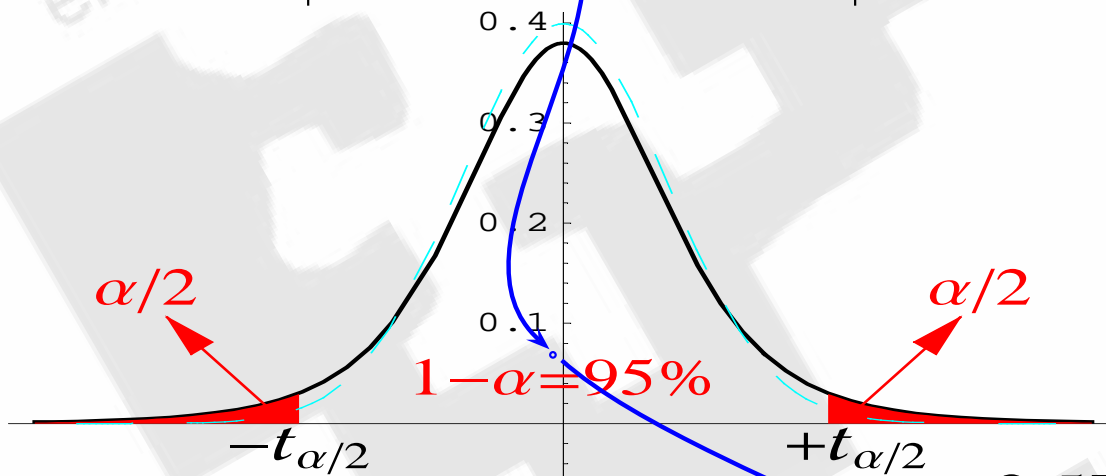
región crítica | región de confianza | región crítica

Intervalo de confianza para β_i

■ Recuérdese que

$$\frac{\hat{\beta}_i - \beta_i}{S_{\hat{\beta}_i}} \sim t(T-K-1)$$

región crítica | región de confianza | región crítica



región crítica | región de confianza | región crítica

es decir: $\Pr[-t_{\alpha/2} \leq \frac{\hat{\beta}_i - \beta_i}{S_{\hat{\beta}_i}} \leq +t_{\alpha/2}] = 1 - \alpha$

$$\Pr[\hat{\beta}_i - t_{\alpha/2} S_{\hat{\beta}_i} \leq \beta_i \leq \hat{\beta}_i + t_{\alpha/2} S_{\hat{\beta}_i}] = 1 - \alpha$$

$IC_{1-\alpha}(\beta_i)$

Intervalo de confianza para β_i (cont)

- Es decir:

$$IC_{1-\alpha}(\beta_i) = [\hat{\beta}_i \pm t_{\alpha/2} S_{\hat{\beta}_i}]$$

- p.ej. para $\alpha = 5\%$, $T-K-1 = 25$, $\hat{\beta}_i = 2,12$ y $S_{\hat{\beta}_i} = 0,08$:

$$\begin{aligned} IC_{95\%}(\beta_i) &= [\hat{\beta}_i \pm t_{2,5\%}(25) S_{\hat{\beta}_i}] \\ &= [\hat{\beta}_i \pm 2,06 S_{\hat{\beta}_i}] = [2,12 \pm 2,06 \cdot 0,08] = [1,9552; 2,2848] \end{aligned}$$

contraste por medio del intervalo de confianza:

Hipótesis: $H_0 : \beta_i = c$ frente a $H_a : \beta_i \neq c$

- **Intervalo:** $IC_{95\%}(\beta_i)$

Regla: Rechazar H_0 : si $c \notin CI_{95\%}(\beta_i)$, con significación del 5%

- p.ej. ¿ $H_0 : \beta_i = 0$? \Rightarrow Rechazar $\Rightarrow \beta_i$ es significativo (al nivel del 5%).

Contraste de única Combinación Lineal

- Supongamos MRLG restringido con 1 restricción ($q = 1$):

$R\beta = r$ pero ahora más sencillo...

$R = d'$ (cualquier fila de $K+1$ valores $d_0, d_1, \dots, +d_K$) y

$r = c$ (cualquier valor escalar):

- Sea $H_0 : \nu = d'\beta = d_0\beta_0 + d_1\beta_1 + \dots + d_K\beta_K = c$

es decir,

un contraste informativo sobre el valor c que toma una única combinación lineal ν de los parámetros.

Contraste de única Combinación Lineal: Ejemplo

- Sea la fn de Cobb-Douglas linealizada

$$\log Y_t = \alpha + \beta_L \log L_t + \beta_K \log K_t + u_t$$

$$d' = \begin{bmatrix} 0 & 1 & 1 \end{bmatrix} \text{ y } c = 1 :$$

-

$$H_0 : \nu = d' \beta = \begin{bmatrix} 0 & 1 & 1 \end{bmatrix} \begin{pmatrix} \alpha \\ \beta_L \\ \beta_K \end{pmatrix} = \beta_L + \beta_K = c = 1$$

es decir, $H_0 : \beta_L + \beta_K = 1$;

el contraste de la hipótesis de **rendimientos de escala constantes**.

Contraste de única Combinación Lineal: dn

- Dado que $\hat{\beta} \sim \mathcal{N}(\beta, \sigma^2(X'X)^{-1})$, tenemos que

$$d'\hat{\beta} \sim \mathcal{N}(d'\beta, \sigma^2 d'(X'X)^{-1}d)$$

$$\hat{\nu} \sim \mathcal{N}(\nu, \text{Var}(\hat{\nu}))$$

donde $\text{Var}(\hat{\nu}) = \sigma^2 \sum_{i,j=0}^K d_i d_j a_{ij}$

- Como antes, estandarizando $\hat{\nu}$

$$\frac{\hat{\nu} - \nu}{\sqrt{\text{Var}(\hat{\nu})}} \sim \mathcal{N}(0, 1)$$

- Por lo tanto (recuérdese que $\sigma \rightarrow \hat{\sigma}$):

$$\Rightarrow \boxed{\frac{\hat{\nu} - \nu}{S_{\hat{\nu}}} \sim t(T-K-1)}$$

donde $S_{\hat{\nu}} = \hat{\sigma} \sqrt{\sum_{i,j=0}^K d_i d_j a_{ij}}$.

Contraste de única Combinación Lineal: regla

- $$\frac{\hat{\nu} - \nu}{S_{\hat{\nu}}} \sim t_{(T-K-1)}$$
- ¿ Qué Contraste ? $\left\{ H_0 : \nu (= d' \beta) = c \right.$ (contraste informativo)
- Recuérdese:** Hipótesis \rightsquigarrow estadístico \rightsquigarrow regla...

- Contraste de una combinación lineal:

- ◆ **Hipótesis:** $H_0 : \nu = c$ frente a $H_a : \nu \neq c$
- ◆ **Estadístico:**


$$t = \frac{\hat{\nu} - c}{S_{\hat{\nu}}} \sim t_{(T-K-1)} \text{ bajo } H_0 :$$

- ◆ **Regla:** $|t| > t_{\alpha/2}(T-K-1) \Rightarrow$ rechazar H_0 :
 \Rightarrow valor de la combinación lineal no es correcta.
- ◆ *compárese* con el contraste de un único parámetro β_k , ¿ algunas similitudes ?.

Contraste de única Combinación Lineal: regla (c)

- Regla: $|t| = \left| \frac{\hat{v} - c}{S_{\hat{v}}} \right| > t_{\alpha/2}(T-K-1) \Rightarrow$ rechaza H_0 :

nivel de significación $\alpha = 5\% = 0,05$



Contraste de única Combinación Lineal: Ejemplo

- En la fn de Cobb-Douglas linealizada:

$$\widehat{\log Y}_t = \widehat{\alpha} + \widehat{\beta}_L \log L_t + \widehat{\beta}_K \log K_t, \quad T = 53;$$

- $\widehat{\log Y}_t = 2,10 + 0,67 \log L_t + 0,32 \log K_t, \quad \widehat{\sigma}^2 = 4;$

$$(X'X)^{-1} = \begin{pmatrix} 2 & 0 & 0 \\ 0 & 4 & -1 \\ 0 & -1 & 7 \end{pmatrix}$$

- Contrastar la H_0 : rendimientos de escala constantes
al nivel de significación del $\alpha = 5\%$:

Contraste de única Combinación Lineal: Ej (cont)

■ **Hipótesis:** $H_0 : \beta_L + \beta_K = 1$ frente a $H_a : \beta_L + \beta_K \neq 1$

■ **Estadístico:**

$$\begin{aligned}\hat{\nu} &= \hat{\beta}_L + \hat{\beta}_K \\ &= 0,67 + 0,27 = 0,89\end{aligned}$$

$$\begin{aligned}S_{\hat{\nu}} &= \sqrt{\widehat{\text{Var}}(\hat{\beta}_L) + \widehat{\text{Var}}(\hat{\beta}_K) + 2\widehat{\text{Cov}}(\hat{\beta}_L, \hat{\beta}_K)} \\ &= \hat{\sigma} \sqrt{a_{11} + a_{22} + 2a_{12}} \\ &= 2\sqrt{4 + 7 + 2(-1)} = 2\sqrt{9} = 6\end{aligned}$$

$$\begin{aligned}t &= \frac{\hat{\nu} - 1}{S_{\hat{\nu}}} \\ &= \frac{0,89 - 1}{6} = \frac{-0,11}{6} = -0,018.\end{aligned}$$

■ **Regla:** $|t| = 0,018 < t_{0,025}(50) = 2,01 \Rightarrow$ no rechazar $H_0 :$

\Rightarrow “rendimientos de escala constantes” es apoyado por datos.

3.2b Contraste de Significatividad Conjunta.

Contraste de Significatividad Conjunta: dn

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

- $H_0 : \beta^* = \mathbf{0} \rightsquigarrow$

- $\hat{\beta}^* \sim \mathcal{N}(\mathbf{0}, \sigma^2 \begin{bmatrix} a_{00} & a_{01} & \dots & a_{0K} \\ a_{10} & a_{11} & \dots & a_{1K} \\ \vdots & \vdots & \dots & \vdots \\ a_{K0} & a_{K1} & \dots & a_{KK} \end{bmatrix}) \sim \mathcal{N}(\mathbf{0}, \sigma^2 (x'x)^{-1})$

- Estandarizar y construir Suma Cuadrados:



$$\frac{\hat{\beta}^{*'} x' x \hat{\beta}^*}{\sigma^2} \sim \chi^2(K) \quad \text{bajo } H_0 :$$

- Entonces (recuérdese el cambio $\sigma^2 \rightarrow \hat{\sigma}^2$):

$$F = \frac{\hat{\beta}^{*'} x' x \hat{\beta}^* / K}{\hat{\sigma}^2} \sim \mathcal{F}_{TK-1}^K$$

Contraste de Significatividad Conjunta: regla

- $$F = \frac{\widehat{\beta}^{*'} x' x \widehat{\beta}^* / K}{\widehat{\sigma}^2} \sim \mathcal{F}_{TK-1}^K \quad \text{bajo } H_0 :$$

- Contraste de significatividad conjunta:** $\left\{ H_0 : \beta^* = 0 \right.$

- Recuérdese:** Hipótesis \rightsquigarrow estadístico \rightsquigarrow regla...

- Hipótesis:** $H_0 : \beta^* = 0$ frente a $H_a : \beta^* \neq 0$ (es decir $\exists \beta_i \neq 0$)

- Estadístico:**

$$\begin{aligned}
 F &= \frac{\widehat{\beta}^{*'} x' x \widehat{\beta}^* / K}{\widehat{\sigma}^2} = \frac{\widehat{y}' \widehat{y} / K}{\widehat{u}' \widehat{u} / (T-K-1)} = \frac{\text{SCE} / K}{\text{SCR} / (T-K-1)} \\
 &= \frac{(\text{SCE} / \text{SCT}) / K}{(\text{SCR} / \text{SCT}) / (T-K-1)} = \frac{R^2 / K}{(1 - R^2) / (T-K-1)} \sim \mathcal{F}_{TK-1}^K \quad \text{bajo } H_0 :
 \end{aligned}$$

- Regla:** $F > \mathcal{F}_\alpha(K, T-K-1) \Rightarrow$ rechazar H_0 :
 - \Rightarrow todos los coefs son conjuntamente significativos (diferentes de cero)
 - \Rightarrow la regresión es (estadísticamente) relevante.


Contraste de Significatividad Conjunta: regla (co

- Regla: $F > \mathcal{F}_\alpha(K, T-K-1) \Rightarrow$ rechazar H_0 :

nivel de significación $\alpha = 5\% = 0,05$

región de confianza

región crítica



región de confianza

región crítica

Contraste de Significatividad Conjunta: Ejemplo

- En el ejemplo anterior (fn de Cobb-Douglas linealizada:)

$$\widehat{\log Y}_t = \hat{\alpha} + \hat{\beta}_L \log L_t + \hat{\beta}_K \log K_t, \quad T = 53;$$

$$\widehat{\log Y}_t = 2,10 + 0,67 \log L_t + 0,32 \log K_t, \quad \hat{\sigma}^2 = 4; R^2 = 0,88$$

- Contrastar significatividad conjunta

con el $\alpha = 5\%$ de significación:

-

$$\begin{aligned} F &= \frac{R^2 / K}{(1 - R^2) / (T - K - 1)} \\ &= \frac{0,88 / 2}{(1 - 0,88) / (50)} = \frac{0,44}{0,024} = 183,33 > \mathcal{F}_{0,05}(2, 50) = 3,19 \end{aligned}$$

- ⇒ β_K y β_L son conjuntamente significativos
- ⇒ regresión es relevante (estadísticamente).

3.3 Contraste General para Restricciones Lineales.

Contraste de Restricciones Lineales: Ejemplo 1

- Recuérdese el MRLG sujeto a q restricciones lineales:

$$Y = X\beta + u, \\ (T \times 1) \quad (T \times K+1) \quad (K+1 \times 1) \quad (T \times 1)$$

$$H_0 : R\beta = r. \\ (q \times K+1) \quad (K+1 \times 1) \quad (q \times 1)$$

- contrastes previos \equiv casos especiales de R.L.s:

1. Sea el MRLG con

$$q = 1, R = \begin{bmatrix} 0 & 0 & 1 & \dots & 0 \end{bmatrix} \text{ y } r = 0 :$$

$$H_0 : R\beta = \begin{bmatrix} 0 & 0 & 1 & \dots & 0 \end{bmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \dots \\ \beta_K \end{pmatrix} = \beta_2 \\ = r = 0$$

es decir, $H_0 : \beta_2 = 0$;

el contraste de **significatividad individual de X_2** .

Contraste de Restricciones Lineales: Ejemplo 2

■ $H_0 : R \beta = r$
 ($q \times K+1$) ($K+1 \times 1$) ($q \times 1$)

3. Sean $q = 2$ restricciones tales que

$$R = \begin{bmatrix} 0 & 2 & 3 & 0 & \dots & 0 \\ 1 & 0 & 0 & -2 & \dots & 0 \end{bmatrix} \text{ y } r = \begin{bmatrix} 5 \\ 3 \end{bmatrix} :$$

$$H_0 : R\beta = \begin{bmatrix} 0 & 2 & 3 & 0 & \dots & 0 \\ 1 & 0 & 0 & -2 & \dots & 0 \end{bmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \\ \dots \\ \beta_K \end{pmatrix} = \begin{bmatrix} 2\beta_1 + 3\beta_2 \\ \beta_0 - 2\beta_3 \end{bmatrix} = \begin{bmatrix} 5 \\ 3 \end{bmatrix}$$

es decir, el MRLG bajo $H_0 : \begin{cases} 2\beta_1 + 3\beta_2 = 5 \\ \beta_0 - 2\beta_3 = 3 \end{cases}$

Contraste de Restricciones Lineales: Ejemplo 3

$$\blacksquare H_0 : R \beta = r .$$

$(q \times K+1) \quad (K+1 \times 1) \quad (q \times 1)$

2. Sean $q = K$ restricciones tales que

$$R = \left[\mathbf{0} \mid \mathbf{I}_K \right] = \begin{pmatrix} 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{pmatrix} \quad \text{y } r = \mathbf{0} = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix}$$

$$\blacksquare H_0 : R\beta = \left[\mathbf{0}_K \mid \mathbf{I}_K \right] \begin{pmatrix} \beta_0 \\ \vdots \\ \beta^* \end{pmatrix} = \beta^* = \mathbf{0}$$

$= r$

es decir, $H_0 : \beta^* = \mathbf{0}$;

el contraste de **significatividad conjunta** de la regresión.

Contrastes de Restricciones Lineales: dn

- ... entonces, ¿ podemos tener un estadístico de contraste general que cubra todas las hipótesis de la forma

$$H_0 : \begin{matrix} R & \beta & = & r & ? \\ (q \times K+1) & (K+1 \times 1) & & (q \times 1) & \end{matrix}$$

- Dado que $\hat{\beta} \sim \mathcal{N}(\beta, \sigma^2(X'X)^{-1})$, tenemos que

$$R\hat{\beta} \sim \mathcal{N}(R\beta, \sigma^2 R(X'X)^{-1}R')$$

- Como antes, estandarizando $R\hat{\beta}$ y escribiendo la SC,

$$\frac{(R\hat{\beta} - R\beta)'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - R\beta)}{\sigma^2} \sim \chi^2(q)$$

- Por lo tanto (recuérdese que cambiar $\sigma^2 \rightarrow \hat{\sigma}^2$):

$$\frac{(R\hat{\beta} - R\beta)'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - R\beta)/q}{\hat{\sigma}^2} \sim \mathcal{F}_{TK-1}^q$$

Contraste General de Restric Lineales: regla

- ¿ Qué Contraste ? $\left\{ H_0 : R\beta = r \right.$
- **Recuérdese:** Hipótesis \rightsquigarrow estadístico \rightsquigarrow regla...
- Contraste de restricciones lineales:
 - ◆ **Hipótesis:** $H_0 : R\beta = r$ frente a $H_a : R\beta \neq r$
 - ◆ **Estadístico:**


$$F = \frac{(R\hat{\beta} - r)'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r)/q}{\hat{\sigma}^2} \sim \mathcal{F}_{TK-1}^q \text{ bajo } H_0 :$$

- ◆ **Regla:** $F > \mathcal{F}_\alpha(q, T-K-1) \Rightarrow$ rechazar H_0 :
 \Rightarrow restricciones lineales no son (conjuntamente) ciertas.

Contraste General de Restric Lineales: regla (con)

- Regla: $F > \mathcal{F}_\alpha(q, T-K-1) \Rightarrow$ rechazar H_0 :

nivel de significación $\alpha = 5\% = 0,05$



3.4 Contrastes basados en la Suma de Cuadrados Residuales.

Contraste General de Restricciones Lineales: regla 2

- **Hipótesis:** $H_0 : R\beta = r$ frente a $H_a : R\beta \neq r$

- **Estadístico:**

$$F = \frac{(R\hat{\beta} - r)'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r)/q}{\hat{\sigma}^2}$$

- utilizando el resultado $\hat{\beta}_R = (I - AR)\hat{\beta} + Ar$, el numerador es la diferencia entre SCs:

$$F = \frac{(\text{SCR}_R - \text{SCR})/q}{\text{SCR}/(T-K-1)} \sim \mathcal{F}_{TK-1}^q \text{ bajo } H_0 :$$

- **Regla:** $F > \mathcal{F}_\alpha(q, T-K-1) \Rightarrow$ rechazar H_0 :
 \Rightarrow restricciones lineales no son (conjuntamente) ciertas.

Contraste General de Restric Lineales: Resumen

- **Hipótesis:** $H_0 : R\beta = r$ frente a $H_a : R\beta \neq r$
- **Estadístico:**

$$F = \frac{(R\hat{\beta} - r)'[R(X'X)^{-1}R']^{-1}(R\hat{\beta} - r)/q}{\hat{\sigma}^2}$$
$$= \frac{(\text{SCR}_R - \text{SCR})/q}{\text{SCR}/(T-K-1)} \sim \mathcal{F}_{TK-1}^q \text{ bajo } H_0 :$$

- **Regla:** $F > \mathcal{F}_\alpha(q, T-K-1) \Rightarrow$ rechazar H_0 :
 \Rightarrow restricciones lineales no son ciertas (conjuntamente).
- **Nota:** la forma SC necesita estimar la regresión dos veces: una con restricciones y otra sin ellas.
- y, por supuesto, también puede utilizarse para contrastar la significatividad individual, la significatividad conjunta, restricciones informativas, etc.

Contraste basado en SC: Ej Cobb-Douglas

■ **Hipótesis:** $H_0 : \beta_L + \beta_K = 1$ frente a $H_a : \beta_L + \beta_K \neq 1$

■ **Estadístico:**

$$\begin{aligned}\hat{\nu} &= \hat{\beta}_L + \hat{\beta}_K \\ &= 0,67 + 0,27 = 0,89\end{aligned}$$

$$\begin{aligned}S_{\hat{\nu}} &= \sqrt{\widehat{\text{Var}}(\hat{\beta}_L) + \widehat{\text{Var}}(\hat{\beta}_K) + 2\widehat{\text{Cov}}(\hat{\beta}_L, \hat{\beta}_K)} \\ &= \hat{\sigma} \sqrt{a_{11} + a_{22} + 2a_{12}} \\ &= 2\sqrt{4 + 7 + 2(-1)} = 2\sqrt{9} = 6\end{aligned}$$

$$\begin{aligned}t &= \frac{\hat{\nu} - 1}{S_{\hat{\nu}}} \\ &= \frac{0,89 - 1}{6} = \frac{-0,11}{6} = -0,018.\end{aligned}$$

■ **Regla:** $|t| = 0,018 < t_{0,025}(50) = 2,01 \Rightarrow$ no rechazar H_0 :

\Rightarrow la hipótesis de “rendimientos de escala constantes.^{es} apoyada por los datos.

Contraste basado en SC: Ej Cobb-Douglas (2)

- Alternativamente, utilizar **forma SC** para calcular este ratio t :

sin restricciones:

$$\log Y = \alpha + \beta_L \log L + \beta_K \log K + u, \quad \rightsquigarrow \quad \mathbf{SCR} = 200$$

- **restringido:** $\log Y = \alpha + \beta_L \log L + (1 - \beta_L) \log K + u$

$$\log(Y/K) = \alpha + \beta_L \log(L/K) + u, \quad \rightsquigarrow \quad \mathbf{SCR}_R = 200,001296$$

-

$$\begin{aligned} F &= \frac{(\mathbf{SCR}_R - \mathbf{SCR})/q}{\mathbf{SCR}/(T-K-1)} \\ &= \frac{(200,001296 - 200)/1}{200/50} = \frac{,001296}{4} = 0,000324 \\ &< \mathcal{F}_{0,05}(1, 50) = 4,04 \end{aligned}$$

- o (recuérdese que $t(m) = \sqrt{\mathcal{F}(1, m)}$)

$$t = \sqrt{F} = \sqrt{0,000324} = 0,018$$

$$< t_{0,05}(50) = 2,01$$

Contraste General: Ejemplo 2

■ MRLG con $q = 2$, $R = \begin{bmatrix} 0 & 2 & 3 & 0 & \dots & 0 \\ 1 & 0 & 0 & -2 & \dots & 0 \end{bmatrix}$ y $r = \begin{bmatrix} 5 \\ 3 \end{bmatrix}$:

$$R\hat{\beta} = \begin{bmatrix} d'_1\hat{\beta} \\ d'_2\hat{\beta} \end{bmatrix} = \begin{bmatrix} 2\hat{\beta}_1 + 3\hat{\beta}_2 \\ \hat{\beta}_0 - 2\hat{\beta}_3 \end{bmatrix}$$

$$R(X'X)^{-1}R' = \begin{bmatrix} d'_1(X'X)^{-1}d_1 & d'_1(X'X)^{-1}d_2 \\ d'_2(X'X)^{-1}d_1 & d'_2(X'X)^{-1}d_2 \end{bmatrix}$$

$$= \begin{bmatrix} 4a_{11} + 9a_{22} + 12a_{12} & 2a_{10} - 4a_{13} + 3a_{02} - 6a_{23} \\ a_{00} + 4a_{33} - 4a_{03} \end{bmatrix}$$

■ Por lo tanto $F =$

$$\frac{\begin{bmatrix} 2\beta_1 + 3\beta_2 - 5 & \beta_0 - 2\beta_3 - 3 \end{bmatrix} \begin{bmatrix} 4a_{11} + 9a_{22} + 12a_{12} & 2a_{10} - 4a_{13} + 3a_{02} - 6a_{23} \\ a_{00} + 4a_{33} - 4a_{03} \end{bmatrix}^{-1} \begin{bmatrix} 2\beta_1 + 3\beta_2 - 5 \\ \beta_0 - 2\beta_3 - 3 \end{bmatrix}}{\hat{\sigma}^2} / 2$$

$\sim \mathcal{F}_{TK-1}^2$ bajo H_0 :

■ es decir, un estadístico “ F ” para contrastar dos restricciones lineales conjuntamente.

Contraste General: Ejemplo 2

- Alternativamente (más fácil), utilizar **forma SC** para calcular este estadístico F :

$$H_0 : \begin{cases} 2\beta_1 + 3\beta_2 = 5 \\ \beta_0 - 2\beta_3 = 3 \end{cases}$$

$$\beta_1 = \frac{5 - 3\beta_2}{2}, \quad \beta_0 = 3 + 2\beta_3$$

- **sin restricciones:**

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 \cdots + u \rightsquigarrow \text{SCR}$$

- **restringido:**

$$Y = (3 + 2\beta_3) + (2,5 - 1,5\beta_2)X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 \cdots + u$$

$$\underbrace{Y - 3 - 2,5X_1}_{Y^*} = \beta_2 \underbrace{(X_2 - 1,5X_1)}_{X_2^*} + \beta_3 \underbrace{(X_3 + 2)}_{X_3^*} + \beta_4 X_4 \cdots + u$$

$$Y^* = \beta_2 X_2^* + \beta_3 X_3^* + \beta_4 X_4 \cdots + u \rightsquigarrow \text{SCR}_R$$

$$y \quad F = \frac{(\text{SCR}_R - \text{SCR})/q}{\text{SCR}/(TK-1)}, \text{ etc.}$$

Contraste General: Ejemplo 3

- MRLG con $q = K$, $R = \begin{bmatrix} \mathbf{0}_K & | & \mathbf{I}_K \end{bmatrix}$ y $r = \mathbf{0}_K$:

$$R\hat{\beta} \rightsquigarrow \text{selecciona } \beta^*$$

$$R(X'X)^{-1}R' \rightsquigarrow \text{selecciona } \begin{bmatrix} a_{00} & a_{01} & \dots & a_{0K} \\ a_{10} & a_{11} & \dots & a_{1K} \\ \vdots & \vdots & \dots & \vdots \\ a_{K0} & a_{K1} & \dots & a_{KK} \end{bmatrix} = (x'x)^{-1}$$

- Por lo tanto:

$$F = \frac{(\hat{\beta}^* - 0)' [(x'x)^{-1}]^{-1} (\hat{\beta}^* - 0) / K}{\hat{\sigma}^2}$$

$$= \frac{\hat{\beta}^{*'} x'x \hat{\beta}^* / K}{\hat{\sigma}^2}$$

- *es decir*, el estadístico “ F ” habitual para contrastar la significación conjunta de la regresión.

Contraste General: Ejemplo 3

- Alternativamente, utilizar **forma SC** para calcular esta F :

sin restricciones: $Y = \beta_0 + \beta_1 X_1 + \dots + \beta_K X_K + u \rightsquigarrow$ **SCR**

restringido: $Y = \beta_0 + u \rightsquigarrow$ **SCR_R = SCT**

- **Estadístico:**

$$\begin{aligned} F &= \frac{(\text{SCR}_R - \text{SCR})/q}{\text{SCR}/(T-K-1)} = \frac{(\text{SCT} - \text{SCR})/K}{\text{SCR}/(T-K-1)} = \frac{\text{SCE}/K}{\text{SCR}/(T-K-1)} \\ &= \frac{R^2/K}{(1 - R^2)/(T-K-1)} \end{aligned}$$

obteniendo la misma formula que antes.

3.5 Predicción por Punto e Intervalo de Predicción.

Predicción

- Capítulos anteriores: **Especificación, Estimación y Validación.**
- Este capítulo: Fase final: **Uso = Predicción.**
- **Punto de partida:** modelo apropiado para describir el comportamiento de la variable Y :

Especificación del Modelo



Estimación de los Parámetros



Validación y Contraste de Hipótesis



resultado no satisfactorio



re-especificar modelo

resultado satisfactorio



ir a la fase de predicción

Concepto

- **Series temporales:** predicción (de valores futuros)
⇒ **Previsión**
- **Sección cruzada:** predicción (de los valores no observados)
⇒ **Simulación**
- **En general:** predicción ⇒ respuesta a preguntas del tipo... “¿y si...?”,
es decir ¿ qué valor tomaría Y si $X = X_p$?

Elementos Básicos

- **Modelo** o FRP:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \cdots + \beta_K X_{Kt} + u_t$$

$$Y_t = X_t' \beta + u_t, \quad t = 1, \dots, T.$$

- Modelo estimado o **FRM**:

$$\hat{Y}_t = X_t' \hat{\beta}, \quad t = 1, \dots, T. \quad (8)$$

- **Observación a predecir**: con subíndice $p =$ (normalmente $p \notin [1, T]$):

$$Y_p = X_p' \beta + u_p. \quad (9)$$

- **Perturbaciones aleatorias** u_p :

$$\mathbf{E}(u_p) = 0, \quad \mathbf{E}(u_p^2) = \sigma^2, \quad \mathbf{E}(u_p u_s) = 0 \quad \forall s \neq p.$$

- Valor conocido del vector X_p' .

Predicción por Punto

- Sustituyendo en FRM (8):

$$\hat{Y}_p = X'_p \hat{\beta}.$$

(10)

es *decir*, valor numérico como aproximación al valor desconocido.

Error de Predicción

- El error cometido (al tomar \hat{Y}_p en vez del verdadero Y_p) es

$$e_p = Y_p - \hat{Y}_p,$$

- que puede expresarse como:
- una función de las **dos fuentes de error** introducidas en la predicción.
- Bajo normalidad:

$$(\hat{\beta} - \beta) \sim \mathcal{N}(0, \sigma^2(X'X)^{-1}), \quad \text{y} \quad u_p \sim \mathcal{N}(0, \sigma^2),$$

- de modo que

$$e_p \sim \mathcal{N}(0, \sigma_e^2),$$

- donde la **varianza del error de predicción** es:

$$\begin{aligned} \sigma_e^2 &= X_p' \underbrace{\text{Var}(\hat{\beta})}_{\sigma^2(X'X)^{-1}} X_p + \underbrace{\text{Var}(u_p)}_{\sigma^2} + \underbrace{\text{Cov}(\hat{\beta}, u_p)}_0 \\ &= \sigma^2(1 + X_p'(X'X)^{-1}X_p). \end{aligned}$$

Intervalo de Predicción

- Error de predicción estandarizado:

$$\frac{e_p - 0}{\sigma_e} = \frac{e_p}{\sigma \sqrt{1 + X'_p(X'X)^{-1}X_p}} \sim \mathcal{N}(0, 1),$$

- Recuérdese como al cambiar $\sigma \rightarrow \hat{\sigma}$ \Rightarrow ¡ $\mathcal{N}(0, 1) \rightarrow \mathbf{t}$!!, luego

$$\frac{e_p}{\hat{\sigma}_e} = \frac{e_p}{\hat{\sigma} \sqrt{1 + X'_p(X'X)^{-1}X_p}} \sim \mathbf{t}(T-K-1).$$

- Por lo tanto:

$$Pr(-\mathbf{t}_{\alpha/2} \leq \frac{e_p}{\hat{\sigma}_e} \leq \mathbf{t}_{\alpha/2}) = 1 - \alpha,$$

- y despejando Y_p :

$$Pr(\hat{Y}_p - \hat{\sigma}_e \mathbf{t}_{\alpha/2} \leq Y_p \leq \hat{Y}_p + \hat{\sigma}_e \mathbf{t}_{\alpha/2}) = 1 - \alpha.$$

- Luego, el **intervalo de confianza** $(1 - \alpha)$ para Y_p es:

$$IC(Y_p)_{(1-\alpha)} = \left[\hat{Y}_p \pm \hat{\sigma}_e \mathbf{t}_{\alpha/2} \right],$$

el cual mide la precisión de la predicción por punto.

Predicción: Ejemplo

- en el ejemplo anterior (fn Cobb-Douglas linealizada :)

$$\widehat{\log Y}_t = \widehat{\alpha} + \widehat{\beta}_L \log L_t + \widehat{\beta}_K \log K_t, \quad T = 53;$$

$$\widehat{\log Y}_t = 2,10 + 0,67 \log L_t + 0,32 \log K_t, \quad \widehat{\sigma}^2 = 4$$

- “¿ Qué valor tomaría Y_p si $\log L_p = 2,5$; $\log K_p = 2,0$?”:

- $X'_p = \begin{bmatrix} 1 & 2,5 & 2,0 \end{bmatrix}$

-

$$\begin{aligned} \widehat{\log Y}_p &= X'_p \widehat{\beta} = \begin{bmatrix} 1 & 2,5 & 2,0 \end{bmatrix} \begin{bmatrix} 2,10 \\ 0,67 \\ 0,32 \end{bmatrix} \\ &= 2,10 + 0,67 \cdot 2,5 + 0,32 \cdot 2,0 = 4,42 \end{aligned}$$

Predicción: Ejemplo

- Construir un IC del 95 % para el verdadero Y_p :

$$\begin{aligned}
 \widehat{\sigma}_e^2 &= \sigma^2 (1 + X_p' (X'X)^{-1} X_p) \\
 &= 4 \left(1 + \begin{bmatrix} 1 & 2,5 & 2,0 \end{bmatrix} \begin{pmatrix} 2 & 0 & 0 \\ 0 & 4 & -1 \\ 0 & -1 & 7 \end{pmatrix} \begin{bmatrix} 1 \\ 2,5 \\ 2,0 \end{bmatrix} \right) \\
 &= 4 \left(1 + \begin{bmatrix} 2 & 8 & 11,5 \end{bmatrix} \begin{bmatrix} 1 \\ 2,5 \\ 2,0 \end{bmatrix} \right) \\
 &= 4 (1 + 45) = 4 \cdot 46 = \mathbf{184}
 \end{aligned}$$

$$\begin{aligned}
 CI(\log Y_p)_{0,95} &= \left[\widehat{\log Y_p} \pm \widehat{\sigma}_e \mathbf{t}_{0,025}(50) \right] \\
 &= \left[4,42 \pm \sqrt{184} \cdot 2,01 \right] \\
 &= [4,42 \pm 27,25] \\
 &= \mathbf{[-22,84 \ ; \ 31,68]}
 \end{aligned}$$

4.1 Variables Ficticias. Definición y uso en el MRLG.

Variables Ficticias: Definición

- **Var explicativa cualitativa** \rightsquigarrow sub-muestras T_1, T_2, \dots
según **categoría o características**
- ejemplos:
 - ◆ **vars puramente cualitativas:**
 - difs individuales: sexo, raza, estado civil, etc.
 - difs temporales: estación, guerra/paz, etc.
 - difs espaciales: países, regiones, urbano/rural, etc.
 - ◆ **vars cuantitativas por tramos:** renta, edad, etc.
- Acordar: no podemos utilizar vars cualitativas...
entonces substituir por **vars ficticias...**
- **Def.** de Variable Ficticia:

$$D_{jt} = \begin{cases} 1, & \text{si } t \in \text{categoria } j ; \\ 0, & \text{si no.} \end{cases}$$

$$\Rightarrow D_{jt} = \mathcal{I}(t \in T_j)$$

1 VC con 2 categorías

Consumo = $f([\text{cte}], \text{renta},$

sexo)



$S_{1t} = \mathcal{I}(t \in M)$ $S_{2t} = \mathcal{I}(t \in F)$

Muestra:

t	Y	cte	R	S
1	Y_1	1	R_1	M
2	Y_2	1	R_2	F
3	Y_3	1	R_3	F
\vdots	\vdots	\vdots	\vdots	\vdots
T	Y_T	1	R_T	M

¿ X ?

t	Y	cte	R	S_1	S_2
1	Y_1	1	R_1	1	0
2	Y_2	1	R_2	0	1
3	Y_3	1	R_3	0	1
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
T	Y_T	1	R_T	1	0

X

En principio: substituir VC por

tantas VFs como categorías haya.

Trampa de Var Ficticias: 1 var cualitativa

- Modelo: $Y_t = \beta_0 + \beta_1 R_t + \gamma_1 S_{1t} + \gamma_2 S_{2t} + u_t$
- **Problema** (Trampa VF):
 X es una matriz ($T \times 4$), pero
 $S_1 + S_2 = [1]$ (c.l. exacta) $\Rightarrow \text{rk}(X) = 3 < 4$ (es decir MC perfecta)
- $\Rightarrow \det(X'X) = 0$
 \Rightarrow ¡ $(X'X)^{-1}$ no existe !! y
¡ no se puede calcular $\hat{\beta}$!!
- **Solución General**: eliminar **UNA** de las cols. que causa el problema: [1] o S_1 o S_2 .
- (POSIBLE Solución: **eliminar intercepto** ... pero...

Solución: VF sin categoría

SOLUCIÓN MÁS HABITUAL: **eliminar categoría: p.ej. F (S_2)**:

■ Modelo **a estimar**:

$$Y_t = \beta_0 + \beta_1 R_t + \gamma_1 S_{1t} + \cancel{\gamma_2 S_{2t}} + u_t$$

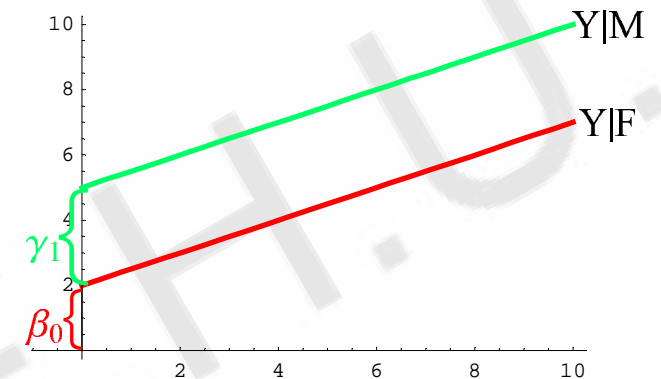
$$= \beta_0 + \beta_1 R_t + \gamma_1 S_{1t} + u_t$$

■ <2> Modelos Submuestras:

$$E(Y_t | S = F) = \beta_0 + \beta_1 R_t$$

$$E(Y_t | S = M) = \beta_0 + \beta_1 R_t + \gamma_1$$

sin categoría F



$$E(Y_t | R_t = 0, S = F) = \beta_0$$

$$E(Y_t | S = M) - E(Y_t | S = F) = \gamma_1$$

■ Interpretación Coeficientes:

Interpretación Coeficientes

$$E(Y_t | S = M) - E(Y_t | S = F) = \gamma_1$$

$$E(Y_t | R_t = 0, S = F) = \beta_0$$

■ <3>es decir,

β_0 = consumo esperado Mujeres (base) si $R_t = 0$.

γ_1 = dif. consumo esperado de Hombres


(frente a base = Mujeres).

β_1 = Δ consumo si $\Delta R_t = 1$ (c.p.).

Recuérdese: Este caso sólo significa **diferentes interceptos para cada categoría.**

Nota: Eliminar una categoría \rightsquigarrow **transformarla en base de referencia.**

sin categoría F



Contrastes Habituales con 1 VC

Hipótesis: variable cualitativa (Sexo) no significativa
(no afecta el Consumo)

es decir *Masc* y *Fem* mismo Consumo:

- **Modelo Sin Restringir**

$$Y_t = \beta_0 + \beta_1 R_t + \gamma S_{1t} + u_t$$


- **Hipótesis:** $H_0 : \gamma = 0$ frente a $H_a : \gamma \neq 0$

- **Modelo Restringido:**

$$Y_t = \beta_0 + \beta_1 R_t + u_t$$

- Véase el habitual Estadístico t (o Estadístico F basado en SCR).

1 VC con 2 cats + 1 VC con 3 cats



$S_{1t} = \mathcal{I}(t \in M)$
 $S_{2t} = \mathcal{I}(t \in F)$

$T_{1t} = \mathcal{I}(t \in A)$
 $T_{2t} = \mathcal{I}(t \in B)$
 $T_{3t} = \mathcal{I}(t \in G)$

Muestra:

t	Y	cte	R	S	T
1	Y_1	1	R_1	M	B
2	Y_2	1	R_2	F	G
3	Y_3	1	R_3	F	B
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
T	Y_T	1	R_T	M	A

¿ X ?

⇒

t	Y	cte	R	S_1	S_2	T_1	T_2	T_3
1	Y_1	1	R_1	1	0	0	1	0
2	Y_2	1	R_2	0	1	0	0	1
3	Y_3	1	R_3	0	1	0	1	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
T	Y_T	1	R_T	1	0	1	0	0

X

Recuérdese: En principio, sustituir var cualitativa por tantas vars Ficticias como categorías haya.

Trampa de Var Ficticias: 2 vars cualitativas

- Modelo: $Y_t = \beta_0 + \beta_1 R_t + \gamma_1 S_{1t} + \gamma_2 S_{2t} + \delta_1 T_{1t} + \delta_2 T_{2t} + \delta_3 T_{3t} + u_t$
- **Problema** (Trampa VF):
 X es una $(T \times 7)$ matriz, pero

$$S_1 + S_2 = T_1 + T_2 + T_3 = [1]$$

(2 c.l. exactas) $\Rightarrow \text{rk}(X) = 5 < 7$ (es decir MC perfecta)

- $\Rightarrow \det(X'X) = 0$
 \Rightarrow ¡ $(X'X)^{-1}$ no existe !! y
 ¡ no se puede calcular $\hat{\beta}$!!
- **Solución General:** eliminar **UNA** de las col's que causa el problema: $[1]$ o $(S_1$ o $S_2)$ o $(T_1$ o T_2 o $T_3)$.

Solución: VF sin combinación de categorías

SOLUCIÓN MÁS HABITUAL:

eliminar última categoría de **cada** VF: S_2 y T_3 :

■ Modelo **a estimar**:

$$Y_t = \beta_0 + \beta_1 R_t + \gamma_1 S_{1t} + \cancel{\gamma_2 S_{2t}} + \delta_1 T_{1t} + \delta_2 T_{2t} + \cancel{\delta_3 T_{3t}} + u_t$$

$$= \beta_0 + \beta_1 R_t + \gamma_1 S_{1t} + \delta_1 T_{1t} + \delta_2 T_{2t} + u_t$$

■ <6> Modelos Submuestras:

	$S = M$	$S = F$	$M - F$
$T = A$	$\beta_0 + \beta_1 R_t + \gamma_1 + \delta_1$	$\beta_0 + \beta_1 R_t + \delta_1$	γ_1
$T = B$	$\beta_0 + \beta_1 R_t + \gamma_1 + \delta_2$	$\beta_0 + \beta_1 R_t + \delta_2$	γ_1
$T = G$	$\beta_0 + \beta_1 R_t + \gamma_1$	$\beta_0 + \beta_1 R_t$	γ_1
$A - G$	δ_1	δ_1	
$B - G$	δ_2	δ_2	
$A - B$	$\delta_1 - \delta_2$	$\delta_1 - \delta_2$	

Coeficiente Interpretación

$$E(Y_t | S = M) - E(Y_t | S = F) = \gamma_1$$

$$E(Y_t | T = A) - E(Y_t | T = G) = \delta_1$$

$$E(Y_t | T = B) - E(Y_t | T = G) = \delta_2$$

$$E(Y_t | R_t = 0, S = F, T = G) = \beta_0$$

■ <5> es decir,

β_0 = consumo esperado Mujeres G (base) if $R_t = 0$.


γ_1 = dif. consumo esperado Hombres frente a Mujeres .

δ_1 = dif. consumo esperado A frente a G .

δ_2 = dif. consumo esperado B frente a G .

β_1 = Δ consumo si $\Delta R_t = 1$ (c.p.).

sin categorías F ni G



Recuérdese: Este caso sólo significa **diferentes interceptos para cada categoría.**

Recuérdese: Eliminar una (combinación de) categoría(s)

~> **transformarla en base de referencia.**

Contrastes habituales con 2 VCs

Hipótesis: Variable Sexo no afecta Consumo
(pero territorio de residencia puede que sí)

■ **Modelo sin Restringir:**

$$Y_t = \beta_0 + \beta_1 R_t + \gamma_1 S_{1t} \\ + \delta_1 T_{1t} + \delta_2 T_{2t} + u_t$$

(γ_1 = dif. esperada Consumo *Masc* frente a *Fem*)

■ **Hipótesis:** $H_0 : \gamma_1 = 0$ frente a $H_a : \gamma_1 \neq 0$

■ **Modelo Restringido:**

$$Y_t = \beta_0 + \beta_1 R_t \\ + \delta_1 T_{1t} + \delta_2 T_{2t} + u_t$$

■ Usar el habitual t Estadístico (o F Estadístico basado en SCR)

Otros Contrastes habituales con 2 VCs

■ Modelo sin Restringir (sin S_2 ni T_3):

$$Y_t = \beta_0 + \beta_1 R_t + \gamma_1 S_{1t} + \delta_1 T_{1t} + \delta_2 T_{2t} + u_t$$

- ◆ Recuérdese: γ_1 es dif. Consumo esperado *Masc* frente a *Fem* (base)
 δ_1 y δ_2 son dif. Consumo esp. de *A* y *B* frente a *G* (base)

■ Hipótesis: Mismo Consumo para todos

(independientemente del Sexo y Territorio):

- ◆ $H_0 : \gamma_1 = \delta_1 = \delta_2 = 0$
- ◆ Modelo Restringido:

$$Y_t = \beta_0 + \beta_1 R_t + u_t$$

■ Hipótesis: Territorio de Residencia no afecta Consumo

(pero *Masc* frente a *Fem* puede que si):

- ◆ $H_0 : \delta_1 = \delta_2 = 0$
- ◆ Modelo Restringido:

$$Y_t = \beta_0 + \beta_1 R_t + \gamma_1 S_{1t} + u_t$$

Otros Contrastes habituales con 2 VCs

- **Modelo sin Restringir** (sin S_2 ni T_3):

$$Y_t = \beta_0 + \beta_1 R_t + \gamma_1 S_{1t} + \delta_1 T_{1t} + \delta_2 T_{2t} + u_t$$

- ◆ Recuérdese: δ_1 y δ_2 son dif. Consumo esperados de A y B frente a G (base)

- **Hipótesis:** Residentes del mismo sexo en A y B tienen el mismo nivel de consumo (pero G puede ser diferente):

- ◆ $H_0 : \delta_1 = \delta_2$ frente a $H_a : \delta_1 \neq \delta_2$

- ◆ **Modelo Restringido:**

$$Y_t = \beta_0 + \beta_1 R_t + \gamma_1 S_{1t} + \underbrace{\delta(T_{1t} + T_{2t})}_{1-T_{3t}} + u_t$$

- **Hipótesis:** Residentes del mismo sexo en B y G tienen el mismo nivel de consumo (pero A puede ser diferente):

- ◆ $H_0 : \delta_2 = 0$ frente a $H_a : \delta_2 \neq 0$

- ◆ **Modelo Restringido:**


$$Y_t = \beta_0 + \beta_1 R_t + \gamma_1 S_{1t} + \delta_1 T_{1t} + u_t$$

4.2 Efecto estacional

Efecto estacional

- Efecto estacional:
-
- Var estacional \rightsquigarrow submuestras T_1, T_2, \dots

según estaciones/meses



Variables Ficticias Estacionales: Definición

- **Def.** Variable Ficticia Estacional:

$$D_{jt} = \begin{cases} 1, & \text{en } t \in \text{estación } j = 1, 2, 3, 4, \dots; \\ 0, & \text{sino.} \end{cases}$$

- *p.ej.* para datos trimestrales:

date (t)	IPI_t	X_t	D_{1t}	D_{2t}	D_{3t}	D_{4t}
1975.1	.	.	1	0	0	0
1975.2	.	.	0	1	0	0
1975.3	.	.	0	0	1	0
1975.4	.	.	0	0	0	1
1976.1	.	.	1	0	0	0
1976.2	.	.	0	1	0	0
1976.3	.	.	0	0	1	0
1976.4	.	.	0	0	0	1
1977.1	.	.	1	0	0	0
⋮	⋮	⋮			...	
2000.1	.	.	1	0	0	0
2000.2	.	.	0	1	0	0
2000.3	.	.	0	0	1	0
2000.4	.	.	0	0	0	1
2001.1	.	.	1	0	0	0
...	

Variables Ficticias Estacionales: Definición (2)

- Modelo a estimar:

$$\begin{aligned}
 IPI_t &= \beta_0 + \beta_1 X_t + \gamma_1 D_{1t} + \gamma_2 D_{2t} + \gamma_3 D_{3t} + \gamma_4 D_{4t} + u_t \\
 &= \beta_0 + \beta_1 X_t + \gamma_1 D_{1t} + \gamma_2 D_{2t} + \gamma_3 D_{3t} + u_t
 \end{aligned}$$

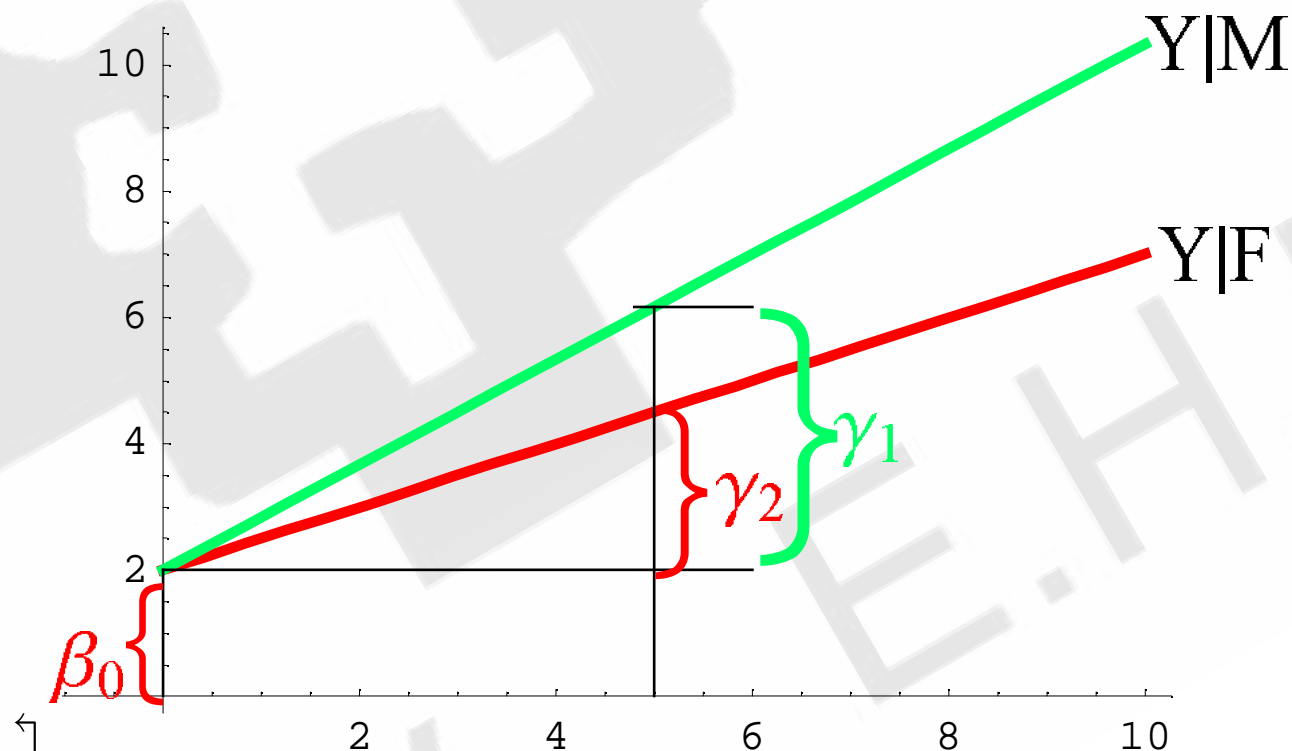
- ¿ Interpretación de los parámetros γ ?
- <1>¿ Qué ocurre si los datos son observaciones mensuales (como de hecho en el ejemplo IPI) ?

fecha (t)	IPI_t	X_t	D_{1t}	D_{2t}	D_{3t}	D_{4t}	ó											
							$D_{1t} \dots$										$\dots D_{12t}$	
1975.ene	.	.	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	
1975.feb	.	.	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	
1975.mar	.	.	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	
1975.abr	.	.	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	
1975.may	.	.	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0	
1975.jun	.	.	0	1	0	0	0	0	0	0	0	1	0	0	0	0	0	
1975.jul	.	.	0	0	1	0	0	0	0	0	0	0	1	0	0	0	0	
1975.ago	.	.	0	0	1	0	0	0	0	0	0	0	0	1	0	0	0	
1975.sep	.	.	0	0	1	0	0	0	0	0	0	0	0	0	1	0	0	
1975.oct	.	.	0	0	0	1	0	0	0	0	0	0	0	0	0	1	0	
1975.nov	.	.	0	0	0	1	0	0	0	0	0	0	0	0	0	1	0	
1975.dic	.	.	0	0	0	1	0	0	0	0	0	0	0	0	0	0	1	
1976.ene	.	.	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	
1976.feb	.	.	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	
1976.mar	.	.	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	
...	

4.3 Interacción entre VFs y Vars cuantitativas

Interacción entre VFs y Vars cuantitativas

En vez de diferentes *interceptos*, necesitamos **diferentes pendientes** para cada categoría:



es decir, diferente **respuesta** “Y” para el mismo “X”

Trampa Var Ficticias: interacción

- <1>Matriz X :

cte	R	$R \times S_1$	$R \times S_2$
1	R_1	$R_1 \times 1$	$R_1 \times 0$
1	R_2	$R_2 \times 0$	$R_2 \times 1$
1	R_3	$R_3 \times 0$	$R_3 \times 1$
⋮	⋮	⋮	⋮
1	R_T	$R_T \times 1$	$R_T \times 0$

 \Rightarrow

cte	R	RS_1	RS_2
1	R_1	R_1	0
1	R_2	0	R_2
1	R_3	0	R_3
⋮	⋮	⋮	⋮
1	R_T	R_T	0

- Modelo:

$$Y_t = \beta_0 + \beta_1 R_t + \gamma_1 R_t S_{1t} + \gamma_2 R_t S_{2t} + u_t$$

- **Problema** (trampa VF): X es matriz $T \times 4$, pero

$$RS_1 + RS_2 = R \Rightarrow \text{rk}(X) = 3 < 4 \quad (\text{MC exacta})$$

- **Solución General**: eliminar **UNA** de las col's que causan el problema: R ó RS_1 ó RS_2 .

Solución: Interacción sin categoría

- SOLUCIÓN MÁS HABITUAL:

eliminar última categoría de la VF: F (RS_2):

- Modelo a estimar:


$$Y_t = \beta_0 + \beta_1 R_t + \gamma_1 R_t S_{1t} + u_t$$

- <2> Modelos Submuestras:

$$E(Y_t | S = F) = \beta_0 + \beta_1 R_t$$

$$E(Y_t | S = M) = \beta_0 + \underbrace{(\beta_1 + \gamma_1)}_{\beta_1^*} R_t$$

⇒



- Interpretación de los coeficientes:

$$E(Y_t | R_t = 0) = \beta_0$$

$$\frac{\partial E(Y_t | S = F)}{\partial R_t} = \beta_1$$

$$\frac{\partial E(Y_t | S = M)}{\partial R_t} = \beta_1 + \gamma_1$$

Interpretación de los coeficientes

$$E(Y_t | R_t = 0) = \beta_0$$

$$\frac{\partial E(Y_t | S = F)}{\partial R_t} = \beta_1$$

$$\frac{\partial E(Y_t | S = M)}{\partial R_t} = \beta_1 + \gamma_1$$

■ <3>es decir,

β_0 = consumo esperado si $R_t = 0$.

β_1 = Δ consumo Mujeres si $\Delta R_t = 1$ (c.p.).


γ_1 = dif Δ consumo para Hombres (frente a base = Mujer).

Recuérdese: Este caso significa **diferentes pendientes para cada categoría**.

Recuérdese una vez más: Eliminar una (combinación de) categoría(s)

~>

transformarla en base de referencia.



Contrastes Habituales con Interacción

Hipótesis: M y F Consumo igual
o la variable Sexo no afecta Consumo:

■ **Modelo sin Restringir:**

$$Y_t = \beta_0 + \beta_1 R_t + \gamma_1 R_t S_{1t} + u_t$$

■ **Hipótesis:** $H_0 : \gamma_1 = 0$ frente a $H_a : \gamma_1 \neq 0$

■ **Modelo Restringido:**

$$Y_t = \beta_0 + \beta_1 R_t + u_t$$

■ Usar el habitual Estadístico t (o Estadístico F basado en SCR)

Fin

FIN