

# Tema 6: Multicolinealidad

Máximo Camacho

# Multicolinealidad

- Bloque I: El modelo lineal clásico
  - × Tema 1: Introducción a la econometría
  - × Tema 2: El modelo de regresión lineal
  - × Tema 3: El método MCO
  - × Tema 4: Propiedades de la estimación MCO
  - × Tema 5: Inferencia y predicción
- Bloque II: Extensiones al modelo lineal clásico
  - × ***Tema 6: Multicolinealidad***
  - × Tema 7: Variables ficticias
  - × Tema 8: Heteroscedasticidad
  - × Tema 9: Endogeneidad

# Descripción de la clase

- Introducción
- Multicolinealidad exacta
  - Consecuencias sobre la estimación
  - ¿Cómo detectarla?
  - ¿Cómo corregirla?
- Multicolinealidad aproximada
  - Consecuencias sobre la estimación
  - ¿Cómo detectarla?
  - ¿Cómo corregirla?
- Conclusiones

# 1. Introducción

## 1.1. Ejemplo de clase

- En California los responsables de educación quieren estudiar notas en 420 colegios. Datos en 1998

- Notas  $Y_i$
  - Ratio estudiantes por profesor  $X_{1i}$  (REP)
  - Porcentaje de alumnos que no hablan bien el idioma  $X_{2i}$  (PNI)
  - Porcentaje de alumnos que pueden pedir ayuda para comedor  $X_{3i}$  (PAC)
  - Porcentaje de alumnos que pueden pedir ayuda por renta baja  $X_{4i}$  (PAR)
- } **nuevas**

- ¿Cómo estimamos esta relación?

- Modelo lineal clásico

# 1. Introducción

## 1.2. Supuestos del modelo lineal clásico

- Suponemos **relación lineal** entre las variables

$$Y_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \varepsilon_i \quad Y = X\beta + \varepsilon \quad Y_i = \chi_i' \beta + \varepsilon_i$$

- Supuestos

- { Exogeneidad débil  $E(\varepsilon_i / \chi_i) = E(\varepsilon_i) = 0$

- } Muestras aleatorias  $\Rightarrow E(\varepsilon_i / \chi_j) = E(\varepsilon_i) = 0 \quad E(\varepsilon_i \varepsilon_j) = E(\varepsilon_i)E(\varepsilon_j) = 0$

Momentos cuartos finitos  $0 < E(\varepsilon_i^4) < \infty, 0 < E(X_{1i}^4) < \infty, \dots, 0 < E(X_{ki}^4) < \infty$

No multicolinealidad exacta  $X_1, \dots, X_n$  no son linealmente dependientes

Normalidad  $\varepsilon / X \sim N$

- Homoscedasticidad  $\text{var}(\varepsilon_i / X) = \sigma^2 \forall i$

## 2. Multicolinealidad exacta

### 2.1. Concepto

#### ■ Definición

- Una o varias variables explicativas son una combinación lineal de otra(s)

#### ■ Ejemplos económicos

- Renta regional<sub>*i*</sub> =  $\beta_0 + \beta_1 \text{interés}_i + \varepsilon_i$
- Cotización<sub>*i*</sub> =  $\beta_0 + \beta_1 \text{ingresos}_i + \beta_2 \text{gastos}_i + \beta_3 \text{beneficio}_i + \varepsilon_i$

#### ■ La matriz de explicativas $X$ tiene columnas linealmente dependientes


$$\begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} 1 & X_{11} & \cdots & X_{k1} \\ 1 & X_{12} & \cdots & X_{k2} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & X_{1n} & \cdots & X_{kn} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

## 2. Multicolinealidad exacta

### 2.2. Implicación para el modelo

- No podemos encontrar de forma única  $\hat{\beta}_{MCO} = (X'X)^{-1}X'Y$

$$\text{rango}(X) < K \Leftrightarrow |X'X| = 0 \Leftrightarrow \nexists (X'X)^{-1}$$

- Teoría: Hemos excluido este caso por supuesto 
- Pero podría aparecer en aplicaciones prácticas
- ¿Cómo detectarlo?
  - Los programas “se quejarán” de que no podemos invertir matriz  $(X'X)$
  - En Eviews aparece el mensaje “near singular matrix”
- ¿Cómo corregirlo?
  - Se deben a errores del investigador al introducir las explicativas
  - Al aparecer mensaje de error, corregiremos las explicativas

## 2. Multicolinealidad exacta

### 2.2. Implicación para el modelo

#### ■ Corrección

- En el ejemplo de la renta regional, supongamos  $\text{interés}_i = 4$

$$\text{Renta regional}_i = \beta_0 + \beta_1 \text{interés}_i + \varepsilon_i \quad \Longrightarrow \quad \text{Renta regional}_i = \beta_0 + \beta_1 4 + \varepsilon_i$$

$$\text{Renta regional}_i = \alpha_0 + \varepsilon_i \quad \alpha_0 = \beta_0 + \beta_1 4$$

- En el ejemplo de la cotización sabemos  $\text{beneficios}_i = \text{ingresos}_i - \text{gastos}_i$

$$\text{Cotización}_i = \beta_0 + \beta_1 \text{ingresos}_i + \beta_2 \text{gastos}_i + \beta_3 \text{beneficio}_i + \varepsilon_i$$

$$\text{Cotización}_i = \alpha_0 + \alpha_1 \text{ingresos}_i + \alpha_2 \text{gastos}_i + \varepsilon_i \quad \left\{ \begin{array}{l} \alpha_0 = \beta_0 \\ \alpha_1 = \beta_1 + \beta_3 \\ \alpha_2 = \beta_2 - \beta_3 \end{array} \right.$$



## 3. Multicolinealidad aproximada

### 3.1. Concepto

#### ■ Definición

- Una o varias variables explicativas son una combinación lineal aproximada de otra(s)
- Supongamos que  $X_1$  es buena explicativa pero comb. lineal aproximada de las demás

$$X_{1i} = \alpha_0 + \alpha_2 X_{2i} + \dots + \alpha_k X_{ki} + u_{1i}$$

#### ■ Ejemplos económicos

- { Porcentaje de alumnos que pueden pedir ayuda por renta baja
- { Porcentaje de alumnos que pueden pedir ayuda para comedor
- { Ayudas que recibe una colegio para libros
- { Ayudas que recibe el colegio para instalaciones
- { Gasto público en carreteras
- { Gasto público en mejorar otras comunicaciones

### 3. Multicolinealidad aproximada

#### 3.2. Implicación para el modelo

- Podemos encontrar de forma única  $\hat{\beta}_{MCO} = (X'X)^{-1}X'Y$

$$\text{rango}(X) = K \Leftrightarrow |X'X| \neq 0 \Leftrightarrow \exists (X'X)^{-1}$$

- Nota: Hemos excluido la multicolinealidad exacta por el supuesto  $\mathbb{W}$
- Estimadores cumplen buenas propiedades y contrastes e intervalos como siempre

- ¿Qué problemas genera en la estimación?

- Para entenderlo, supongamos que hacemos la regresión

$$X_{1i} = \alpha_0 + \alpha_2 X_{2i} + \dots + \alpha_k X_{ki} + u_{1i}$$

- Y definimos

$$R_1^2 = 1 - \frac{SCR_1}{STC_1} = 1 - \frac{\sum \hat{u}_{1i}^2}{\sum (X_{1i} - \bar{X}_1)^2}$$

### 3. Multicolinealidad aproximada

#### 3.2. Implicación para el modelo

■ ¿Qué problemas genera en la estimación?

- Podemos demostrar (ejercicios de clase y Wooldridge, pág. 102) que

$$\hat{\beta}_1 = \beta_1 + \frac{\sum \hat{u}_{1i} \varepsilon_i}{\sum \hat{u}_{1i}^2} \Rightarrow \text{var}(\hat{\beta}_1/X) = \frac{\sigma^2}{\sum \hat{u}_{1i}^2} = \frac{\sigma^2}{(1 - R_1^2) \sum (X_{1i} - \bar{X}_1)^2}$$

- Cuanta mayor relación lineal entre  $X_1$  y el resto mayor varianza de  $\hat{\beta}_1$
- Estimación imprecisa e intervalos de confianza muy grandes  $\left( \hat{\beta}_1 \pm t_{n-K, \alpha/2} \sqrt{\widehat{\text{var}}(\hat{\beta}_1)} \right)$
- Ejemplos:
  - Si  $X_1$  no se relacionara ( $R_1^2 = 0$ )  $\text{var}(\hat{\beta}_1/X) = \sigma^2 / \sum (X_{1i} - \bar{X}_1)^2$
  - Si  $R_1^2 = 0.5$  esa varianza se duplica
  - Si  $R_1^2 = 0.9$  esa varianza se multiplica por 10

### 3. Multicolinealidad aproximada

#### 3.2. Implicación para el modelo

■ Ejemplo simulado (Novales, pág 346)

- Se generan 50 tripletas de vectores (112 x 1)  $(\varepsilon^j, X_1^j, X_2^j)$  (j=1, 2, ...50)
- Bajo 3 supuestos de  $R^2_i$  (0, 0.9 y 0.99). Siempre se cumplen los supuestos clásicos
- Se generan  $Y^j$  conociendo la recta poblacional  $Y_i^j = 8 + 5X_{1i}^j - 3X_{2i}^j + \varepsilon_i^j$
- Se estima MCO 50 veces y los resultados medios

Medias	$R^2_i = 0.00$	$R^2_i = 0.90$	$R^2_i = 0.99$
$\hat{\beta}$	( 8.0 , 5.1, -3.0 )	( 7.9, 5.1,-3.2 )	( 7.9, 5.2, -3.3 )
$\text{var}(\hat{\beta}_1)$	0.23	1.29	11.22
$\text{var}(\hat{\beta}_2)$	0.23	1.06	11.03

→ casi esperanzas (insesgados)  
} aumentan mucho

### 3. Multicolinealidad aproximada

#### 3.2. Implicación para el modelo


- Puede indicar artificialmente variables no son significativas individualmente

- Supongamos que hacemos el contraste

$$Y_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \varepsilon_i \quad H_0 : \beta_i = 0 \quad H_a : \beta_i \neq 0$$

- El estadístico tiene varianza muy grande y tiende a caer en zona de no  $RH_0$ 
  - × Con independencia de que  $X_j$  se relacione con  $Y$
  - × Aunque el  $R^2_c$  sea alto y no caiga al quitar  $X_j$

$$t^* = \frac{\hat{\beta}_i}{\sqrt{\hat{\text{var}}(\hat{\beta}_i)}} \sim t_{n-K}$$

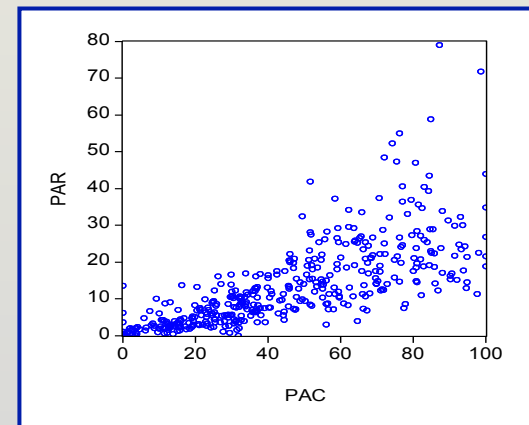

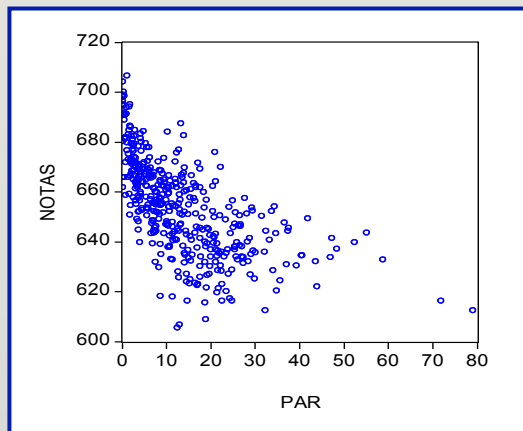


## 3. Multicolinealidad aproximada

### 3.3. Métodos de detección de multicolinealidad

#### ■ Método 1: gráficos de las explicativas

- En nuestro ejemplo  $Notas_i = \beta_0 + \beta_1 REP_i + \beta_2 PNI_i + \beta_3 PAC_i + \beta_4 PAR_i + \varepsilon_i$
- Esperamos que PAR y PAC se relacionen (negativamente) con la dependiente
- Esperamos que PAR y PAC se relacionen linealmente (y positivamente)
- **Crítica:** los gráficos siempre nos pueden engañar



## 3. Multicolinealidad aproximada

### 3.3. Métodos de detección de multicolinealidad

- Método 2: regresar explicativas entre ellas y ver  $R^2_j$

- Sabemos que 
$$\text{var}(\hat{\beta}_j / X) = \frac{\sigma^2}{(1 - R_j^2) \sum (X_{ji} - \bar{X}_j)^2}$$
- El problema viene dado por  $R^2_j$  altos que indican alta relación lineal
- Veamos como son los  $R^2_j$

$$REP_i = \alpha_0 + \alpha_1 PNI_i + \alpha_2 PAC_i + \alpha_3 PAR_{3i} + \varepsilon_i \Rightarrow R_1^2 = 0.04$$

$$PNI_i = \alpha_0 + \alpha_1 REP_i + \alpha_2 PAC_i + \alpha_3 PAR_{3i} + \varepsilon_i \Rightarrow R_2^2 = 0.49$$

$$PAR_i = \alpha_0 + \alpha_1 REP_i + \alpha_2 PNI_i + \alpha_3 PAC_{3i} + \varepsilon_i \Rightarrow R_3^2 = 0.60$$

$$PAC_i = \alpha_0 + \alpha_1 REP_i + \alpha_2 PNI_i + \alpha_3 PAR_{3i} + \varepsilon_i \Rightarrow R_4^2 = 0.74$$

- Parece que el problema puede estar con PAR o con PAC

## 3. Multicolinealidad aproximada

### 3.3. Métodos de detección de multicolinealidad

- **Crítica** ¿cómo de grande debe ser  $R_j^2$  para preocuparnos por multicolinealidad?

- × En la literatura ha habido algunos intentos de acotarlo

- × Ej: Klien (1962). Sólo nos preocupa si  $R_j^2 > R^2$

$$Notas_i = \beta_0 + \beta_1 REP_i + \beta_2 PNI_i + \beta_3 PAC_i + \beta_4 PAR_i + \varepsilon_i \Rightarrow R^2 = 0.77$$

$$PAR_i = \alpha_0 + \alpha_1 REP_i + \alpha_2 PNI_i + \alpha_3 PAC_{3i} + \varepsilon_i \Rightarrow R_3^2 = 0.60$$

$$PAC_i = \alpha_0 + \alpha_1 REP_i + \alpha_2 PNI_i + \alpha_3 PAR_{3i} + \varepsilon_i \Rightarrow R_4^2 = 0.74$$

- × ¿Debemos preocuparnos por multicolinealidad?

- No hay ninguna razón objetiva para usar esta cota



### 3. Multicolinealidad aproximada

#### 3.3. Métodos de detección de multicolinealidad

■ Método 3: regresar explicativas entre ellas y contrastes significatividad conjunta

- Sabemos que  $REP_i = \alpha_0 + \alpha_1 PNI_i + \alpha_2 PAC_i + \alpha_3 PAR_i + \varepsilon_i$


- CSC:  $H_0 : \alpha_1 = 0, \alpha_2 = 0, \alpha_3 = 0$   $F_j^* = \frac{R_j^2 / 3}{(1 - R_j^2) / (n - 4)}$

$$REP_i = \alpha_0 + \alpha_1 PNI_i + \alpha_2 PAC_i + \alpha_3 PAR_{3i} + \varepsilon_i \Rightarrow F_1^* = 5.77$$

$$PNI_i = \alpha_0 + \alpha_1 REP_i + \alpha_2 PAC_i + \alpha_3 PAR_{3i} + \varepsilon_i \Rightarrow F_2^* = 133$$

$$PAR_i = \alpha_0 + \alpha_1 REP_i + \alpha_2 PNI_i + \alpha_3 PAC_{3i} + \varepsilon_i \Rightarrow F_3^* = 208$$

$$PAC_i = \alpha_0 + \alpha_1 REP_i + \alpha_2 PNI_i + \alpha_3 PAR_{3i} + \varepsilon_i \Rightarrow F_4^* = 394$$



- **Crítica.** Con  $n$  grande  $RH_0$  con demasiada frecuencia: recuerda que  $R^2_1 = 0.04$  !!!

## 3. Multicolinealidad aproximada

### 3.3. Métodos de detección de multicolinealidad

#### ■ Método 4: contradicción contraste significatividad global e individuales

- Supongamos que en el modelo

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \beta_3 X_{3i} + \beta_4 X_{4i} + \varepsilon_i$$

- Las explicativas  $X_{2i}$ ,  $X_{3i}$  y  $X_{4i}$  se relacionan casi linealmente
- Si las variables se relacionan con la dependiente
  - × El contraste de significatividad global, menos afectado por la multicolinealidad, puede indicar significatividad (incluso al 1%)
  - × Y el  $R^2$  puede ser alto indicando un buen ajuste
- Sus contrastes de significatividad individuales
  - × Pueden indicar no significatividad
  - × Sólo una variable ( $X_{1i}$ ) significativa

### 3. Multicolinealidad aproximada



#### 3.3. Métodos de detección de multicolinealidad

- **Crítica:** casos tan claros no los tendremos en la realidad

$$\widehat{Notas}_i = 700.39 - \underset{(4.69)}{1.01} REP_i - \underset{(0.23)}{0.13} PNI_i - \underset{(0.03)}{0.52} PAC_i - \underset{(0.06)}{0.04} PAR_i \Rightarrow R^2 = 0.77$$

$$t_i^* = \frac{\hat{\beta}_i}{\sqrt{\widehat{\text{var}}(\hat{\beta}_i)}} \begin{cases} t_1^* = -4.23 \\ t_2^* = -3.81 \\ t_3^* = -16.42 \\ t_4^* = -0.78 \end{cases}$$

$$F^* = \frac{R^2/4}{(1-R^2)/(n-5)} = 357$$



## 3. Multicolinealidad aproximada

### 3.3. Métodos de detección de multicolinealidad

- × Globalmente significativas
- × PAR es la única no significativa
- × ¿Se debe a multicolinealidad o a que no es una buena explicativa?
  - Si se debe a multicolinealidad: vamos a ver soluciones
  - Si no se relaciona con la dependiente: deberíamos quitarla del modelo
  - ¿Pero cómo lo sabremos?
  - Lo mejor es acudir al sentido común
- × ¿Cuáles son las soluciones a la multicolinealidad?

## 3. Multicolinealidad aproximada

### 3.4. Soluciones a la multicolinealidad

#### ■ Solución 1: añadir información extra-muestral

- Ampliar la muestra: usando otros colegios de California
  - × **Crítica:** debemos usar toda la información disponible en la primera estimación

- Usar la estimación de otra muestra

- × Supongamos que usando datos de Texas hemos estimado

$$\widehat{Notas}_i = -0.20PAR_i$$

- × Para los datos de California estimamos

$$Notas_i = \beta_0 + \beta_1 REP_i + \beta_2 PNI_i + \beta_3 PAC_i - 0.20PAR_i + \varepsilon_i$$

- × **Crítica:** ¿por qué  $\hat{\beta}_4^{Texas} = \hat{\beta}_4^{California}$  ?  $\Rightarrow$  Restricciones falsas sesgan la estimación

# 3. Multicolinealidad aproximada

## 3.4. Soluciones a la multicolinealidad

### ■ Solución 2: Usar estimadores alternativos a MCO

- Estimador de Cresta

- × Buscamos un  $c$  y un estimador de menor varianza

$$\hat{\beta}_c = (X'X + cI)^{-1} X'Y \quad \text{var}(\hat{\beta}_c/X) = \sigma^2 (X'X + cI)^{-1} X'X (X'X + cI)^{-1}$$

- × **críticas**: el estimador propuesto es sesgado y cómo elegir  $c$

- Estimador de componentes principales

- × Buscamos combinación lineal de las columnas de  $X$ :  $Z = XB$

- ×  $B$  se busca de forma que las  $Z_i$  sean ortogonales (elimina multicolinealidad)

- × Regresamos usando  $Z$   $Y = Z\alpha + \varepsilon$

- × **críticas**:  $\hat{\alpha}$   $\left\{ \begin{array}{l} \text{difíciles de interpretar} \\ \text{sesgados} \end{array} \right\}$  da igual si objetivo es predecir

## 3. Multicolinealidad aproximada

### 3.4. Soluciones a la multicolinealidad

- Solución 3: Eliminar la variable no significativa ( $PAR_i$ )
  - (Ver tema 5: consecuencias de imponer restricciones ciertas y falsas)
  - Supongamos que eliminamos la variable: imponemos  $\beta_4 = 0$ 
    - × Si no se relaciona con las notas  $\Rightarrow$  Imponemos una restricción cierta  
(No sesgo y reducimos la varianza)
    - × Si se relaciona con las notas  $\Rightarrow$  Imponemos una restricción falsa  
(Introducimos sesgo y reducimos la varianza)
  - ¿Cuándo merece la pena asumir el riesgo de eliminarla?
    - × Analizaremos el error cuadrático medio

### 3. Multicolinealidad aproximada

#### 3.4. Soluciones a la multicolinealidad

- × Supongamos un modelo más sencillo

$$Y_i = \beta_1 X_{1i} + \beta_2 X_{2i} + \varepsilon_i \implies \hat{\beta}_1$$

- × Pensamos que  $X_2$  presenta problemas de multicolinealidad con  $X_3$  : si  $\beta_2 = 0$

$$Y_i = \beta_1 X_{1i} + \varepsilon_i \implies \tilde{\beta}_1$$

- × ¿ECM? (Ejercicios de clase y Novales, pág 361)

$$ECM(\tilde{\beta}_1) = \text{var}(\hat{\beta}_1) + \text{sesgo}^2$$

$$\frac{ECM(\tilde{\beta}_1)}{ECM(\hat{\beta}_1)} = 1 + R_2^2(t^2 - 1)$$

$$t = \left( \frac{\beta_i}{\sqrt{\text{var}(\beta_i)}} \right)$$

- × Sólo merece la pena si  $|t| < 1 \implies$  algunos autores piden  $|t^*| \ll 1$

- × **críticas:**
  - ¿Cuánto podemos considerar  $t^* \ll 1$ ?
  - ¿Queremos estimadores sesgados?



### 3. Multicolinealidad aproximada

#### 3.4. Soluciones a la multicolinealidad

× En nuestro ejemplo

$$\widehat{Notas}_i = 700.39 - 1.01 REP_i - 0.13 PNI_i - 0.52 PAC_i - 0.04 PAR_i$$

(4.69)      (0.23)      (0.03)      (0.03)      (0.06)

$$|t_4^*| = \left| \frac{\hat{\beta}_4}{\sqrt{\widehat{\text{var}}(\hat{\beta}_4)}} \right| = 0.78$$

× ¿Qué hacemos?

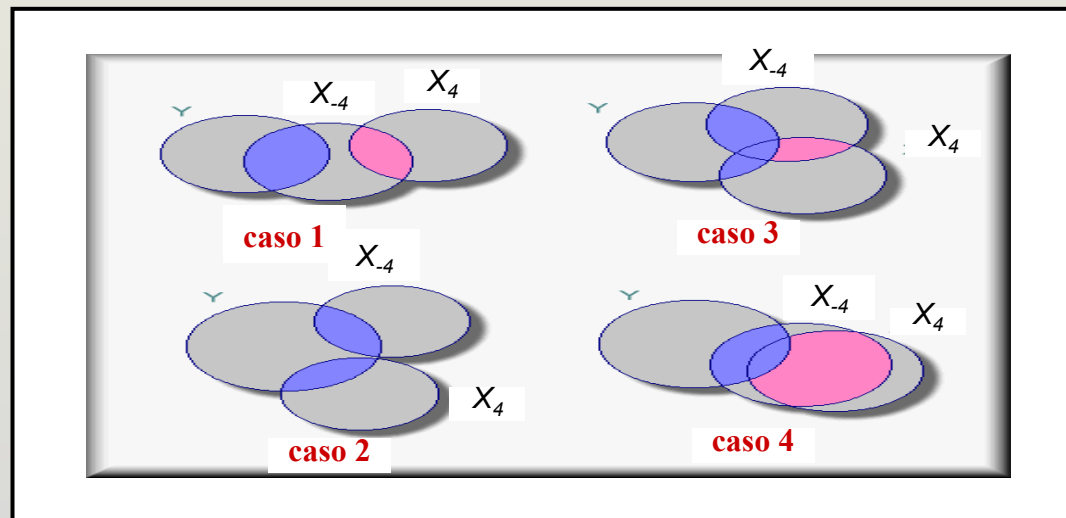
- Mi consejo es acudir al sentido común (teoría económica)
- Parece que tanto PAC como PAR contienen la misma información sobre los colegios: nos dicen cuáles tienen más alumnos pobres
- Podemos eliminar PAR porque PAC ya contiene la información necesaria para estimar el modelo de notas

$$\widehat{Notas}_i = 700.15 - 0.99 REP_i - 0.12 PNI_i - 0.55 PAC_i$$


(4.69)      (0.24)      (0.03)      (0.02)

## 4. Conclusión

- $X_4$  puede tener distintas relaciones con las demás ( $X_{-4}$ ) y la dependiente
  - )  $X_4$  no explicativa y multico, :  $X_4$  la eliminamos con contrastes
  - (  $X_4$  explicativa y no multico,  $X_4$  explicativa:  $X_4$  será explicativa final
  - )  $X_4$  explicativa y multico no severa:  $X_4$  será explicativa tras los contrastes
  - (  $X_4$  explicativa y multico severa: acudir al sentido común más contrastes



## 5. ¿Qué hemos aprendido?

- Multilinealidad
  - Relación lineal entre las variables explicativas del modelo
- Exacta
  - Teoría: nunca hay porque suponemos 
  - Práctica: fácil de detectar y resolver
- Aproximada
  - Da lugar a estimaciones imprecisos, varianzas e intervalos de confianza grandes
  - Difícil de detectar y de corregir
- ¿Qué hacer?
  - Asegurarnos de que tenemos multilinealidad: todas pruebas y teoría económica
  - No significativa y la información sobre  $Y$  ya está en las que quedan: eliminarla
  - No significativa pero la información sobre  $Y$  ya está en las que quedan: la dejamos