

TEMA 3. EL MODEL DE REGRESSIÓ MÚLTIPLE: ESTIMACIÓ

Joan Llull

Materials: <http://pareto.uab.cat/jllull>

Tutories: dijous de 11:00 a 13:00h
(concertar cita per email)
—Despatx B3-1132—

joan.llull [at] movebarcelona [dot] eu

T3. EL MODEL DE REGRESSIÓ MÚLTIPLE: ESTIMACIÓ

- 1** El model de regressió amb K variables
- 2** L'estimador Mínim Quadrat Ordinari: MQO
- 3** Distribució de l'estimador MQO
- 4** L'estimador Mínim Quadrat Restringit: MQR
- 5** Aplicacions
- 6** Variables fictícies

T3. EL MODEL DE REGRESSIÓ MÚLTIPLE: ESTIMACIÓ

- 1 El model de regressió amb K variables
- 2 L'estimador Mínim Quadrat Ordinari: MQO
- 3 Distribució de l'estimador MQO
- 4 L'estimador Mínim Quadrat Restringit: MQR
- 5 Aplicacions
- 6 Variables fictícies

Motivació

La **publicitat**, el nombre d'**establiments** es comercialitza, la quantitat de **calci** de la llet... poden ser altres determinants del nombre de ampolles de llet venudes (a més del preu)

El **capital humà**, el nivell d'**obertura internacional**, la mida del **sector públic**,... poden ser altres determinants del PIB per càpita d'un país (a més del capital per càpita)

Els anys d'**experiència** en el sector, l'**antiguitat**, la **mida de l'empresa**,... poden ser altres determinants del salari (a més dels anys d'educació)

⇒ Necessitarem ampliar el model a K **variables** (model de regressió múltiple)

El model de regressió múltiple

Ara volem tenir K **variables** explicatives en lloc de una:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_{K-1} x_{iK-1} + u_i \quad u_i \sim \mathcal{N}(0, \sigma^2)$$

Per tant, donades les nostres N **observacions**, tindrem el següent sistema d'equacions:

$$\left\{ \begin{array}{l} y_1 = \beta_0 + \beta_1 x_{11} + \beta_2 x_{12} + \cdots + \beta_{K-1} x_{1K-1} + u_1 \quad u_1 \sim \mathcal{N}(0, \sigma^2) \\ y_2 = \beta_0 + \beta_1 x_{21} + \beta_2 x_{22} + \cdots + \beta_{K-1} x_{2K-1} + u_2 \quad u_2 \sim \mathcal{N}(0, \sigma^2) \\ \vdots \\ y_N = \beta_0 + \beta_1 x_{N1} + \beta_2 x_{N2} + \cdots + \beta_{K-1} x_{NK-1} + u_N \quad u_N \sim \mathcal{N}(0, \sigma^2) \end{array} \right.$$

Interpretació?

Això també ho podem transformar a **notació matricial** (piss.)

El model de regressió múltiple: notació matricial

El model en notació matricial quedaria expressat de la següent manera:

$$y = X\beta + u \quad U \sim \mathcal{N}(0, \sigma^2 I_N)$$

on:

$$y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix} \quad X = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1K-1} \\ 1 & x_{21} & x_{22} & \dots & x_{2K-1} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & x_{N1} & x_{N2} & \dots & x_{NK-1} \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_{K-1} \end{bmatrix} \quad u = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_N \end{bmatrix}$$

Dimensions?

Supòsits

Novament treballarem amb x **fixes**. Els **supòsits** seran els mateixos que en el tema anterior, i la seva interpretació també.

Podem veure'ls implícitament a l'expressió $u \sim \mathcal{N}(0, \sigma^2 I_N)$:

- $\mathbb{E}[u] = \begin{bmatrix} \mathbb{E}[u_1] \\ \mathbb{E}[u_2] \\ \vdots \\ \mathbb{E}[u_N] \end{bmatrix} =$
- $\text{Var}(u) = \begin{bmatrix} \text{Var}(u_1) & \text{Cov}(u_1, u_2) & \dots & \text{Cov}(u_1, u_N) \\ \text{Cov}(u_1, u_2) & \text{Var}(u_2) & \dots & \text{Cov}(u_2, u_N) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(u_1, u_2) & \text{Cov}(u_2, u_N) & \dots & \text{Var}(u_N) \end{bmatrix} =$
- $u \sim$

T3. EL MODEL DE REGRESSIÓ MÚLTIPLE: ESTIMACIÓ

- 1 El model de regressió amb K variables
- 2 L'estimador Mínim Quadrat Ordinari: MQO
- 3 Distribució de l'estimador MQO
- 4 L'estimador Mínim Quadrat Restringit: MQR
- 5 Aplicacions
- 6 Variables fictícies

Estimació amb K variables

Com ja sabem, l'estimador MQO minimitza la suma dels quadrats dels residus:

$$\min_{\hat{\beta}} \hat{u}'\hat{u}$$

Com hem vist en el tema 2:

$$\hat{\beta} = (X'X)^{-1}X'y$$

Dimensions?

Els residus

Els **residus** són l'equivalent mostral al terme de pertorbació:

$$\hat{u} = y - \hat{y} = y - X\hat{\beta} \quad \Leftrightarrow \quad \hat{u}_i = y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \cdots - \hat{\beta}_{K-1} x_{iK-1}$$

Recordeu també la **propietat numèrica** que vam derivar en el tema 2:

$$X'\hat{u} = 0$$

Quines propietats inclou ara?

El coeficient de determinació i el coeficient de determinació ajustat

El **coeficient de determinació** ens indicava quina proporció de la variació de y ve explicada pel model:

$$R^2 = \frac{SQE}{SQT} = 1 - \frac{SQR}{SQT} = 1 - \frac{\hat{u}'\hat{u}}{(y - \bar{y}\iota)'(y - \bar{y}\iota)} = 1 - \frac{\widehat{\text{Var}}(\hat{u})}{\widehat{\text{Var}}(y)}$$

Problema: sempre augmenta quan augmentem el nombre de variables.

Solució: coeficient de determinació ajustat (o corregit):

$$\bar{R}^2 = 1 - \frac{SQR/(N - K)}{SQT/(N - 1)} = 1 - \frac{SQR}{SQT} \frac{N - 1}{N - K} \leq R^2$$

T3. EL MODEL DE REGRESSIÓ MÚLTIPLE: ESTIMACIÓ

- 1 El model de regressió amb K variables
- 2 L'estimador Mínim Quadrat Ordinari: MQO
- 3** Distribució de l'estimador MQO
- 4 L'estimador Mínim Quadrat Restringit: MQR
- 5 Aplicacions
- 6 Variables fictícies

L'esperança i la variança de l'estimador

Recordem que $\hat{\beta}$ és una **variable aleatòria**.

Igual com en el tema anterior, podem escriure:

$$\hat{\beta} = \beta + (X'X)^{-1}X'u \Rightarrow \hat{\beta} \text{ és un } \mathbf{estimador lineal} \text{ de } \beta.$$

$$\mathbb{E}[\hat{\beta}] = \begin{bmatrix} \mathbb{E}[\hat{\beta}_0] \\ \mathbb{E}[\hat{\beta}_1] \\ \vdots \\ \mathbb{E}[\hat{\beta}_{K-1}] \end{bmatrix} = \beta \Rightarrow \hat{\beta} \text{ és un estimador } \mathbf{no esbiaixat} \text{ de } \beta.$$
$$\text{Var}(\hat{\beta}) = \begin{bmatrix} \text{Var}(\hat{\beta}_0) & \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) & \dots & \text{Cov}(\hat{\beta}_0, \hat{\beta}_{K-1}) \\ \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) & \text{Var}(\hat{\beta}_1) & \dots & \text{Cov}(\hat{\beta}_1, \hat{\beta}_{K-1}) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(\hat{\beta}_0, \hat{\beta}_{K-1}) & \text{Cov}(\hat{\beta}_1, \hat{\beta}_{K-1}) & \dots & \text{Var}(\hat{\beta}_{K-1}) \end{bmatrix} = \sigma^2(X'X)^{-1}.$$


(demostracions pissarra)

Distribució de l'estimador MQO

Per tant, igual que en el tema anterior, $\hat{\beta} \sim \mathcal{N}(\beta, \sigma^2(X'X)^{-1})$.

Dimensions?

Per tant, $\hat{\beta}_{K-1} \sim \mathcal{N}(\beta_{K-1}, \sigma^2(X'X)_{kk}^{-1})$:



$\text{Var}(\hat{\beta}) = \sigma^2(X'X)^{-1}$ no és conegut. Per tant, ho estimarem:

$$\widehat{\text{Var}}(\hat{\beta}) =$$

El teorema de Gauss-Markov

Teorema de Gauss-Markov: “Sota els supòsits clàssics, MQO és l'estimador lineal no esbiaixat amb menor varianza.”

Aquest teorema:

- està comparant $\hat{\beta}$ amb els altres **estimadors lineals** (és a dir, els que es podem escriure com Ay o, el que és el mateix, com $Bu + c$).
- que són **no esbiaixats** (per exemple, un estimador que fos $\tilde{\beta} = 0$ tindria menor varianza, però, en general, seria esbiaixat).

T3. EL MODEL DE REGRESSIÓ MÚLTIPLE: ESTIMACIÓ

- 1 El model de regressió amb K variables
- 2 L'estimador Mínim Quadrat Ordinari: MQO
- 3 Distribució de l'estimador MQO
- 4 L'estimador Mínim Quadrat Restringit: MQR
- 5 Aplicacions
- 6 Variables fictícies

Motivació

Si tenim informació rellevant dels paràmetres és eficient usar-la en l'estimació. En aquest tema parlarem de **restriccions lineals d'igualtat**.

Per exemple, imaginem que volem estimar la funció de producció **Cobb-Douglas amb dades agregades**:

$$Y = AK^\alpha L^{1-\alpha}.$$

Si prenem logaritmes, el model serà:

$$\ln Y_i = \ln A + \alpha \ln K_i + (1 - \alpha) \ln L_i.$$

Per tant, el nostre **model economètric** seria:

$$\ln Y_i = \beta_0 + \beta_1 \ln K_i + \beta_2 \ln L_i + u_i \quad s.a. \quad \beta_2 = 1 - \beta_1.$$

Les restriccions

Com hem vist abans, treballarem amb **restriccions lineals d'igualtat**.

algebra matricial?

$$\begin{aligned} \text{Model 1: } & y_i = \beta_0 + \beta_1 x_{i1} + u_i \\ \text{restricció: } & \beta_0 = 2 \end{aligned} \quad \rightarrow$$

$$\begin{aligned} \text{Model 2: } & y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i \\ \text{restricció: } & \beta_1 + \beta_2 = 1 \end{aligned} \quad \rightarrow$$

$$\begin{aligned} \text{Model 3: } & y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i \\ \text{restricció: } & \beta_1 = 2\beta_2 \end{aligned} \quad \rightarrow$$

$$\begin{aligned} \text{Model 4: } & y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_4 x_{i4} + u_i \\ \text{restricció: } & \beta_1 = 0 \quad \beta_2 + \beta_4 = 1 \end{aligned} \quad \rightarrow$$

Recapitulació

Fixem-nos que qualsevol d'aquestes **restriccions** les podem escriure en **forma matricial** amb la següent estructura:

$$R\beta = r$$

Dimensions?

A continuació veurem dues formes d'**estimar** el model restringit:

- El **mètode de substitució**.
- L'estimador **mínim quadrat restringit** (MQR).

Mètode de substitució

El **mètode de substitució** consisteix en rescriure el model integrant la restricció i després estimar el “**model restringit**” per MQO:

model restringit?

Model 1: $y_i = \beta_0 + \beta_1 x_{i1} + u_i$
restricció: $\beta_0 = 2$ →

Model 2: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i$
restricció: $\beta_1 + \beta_2 = 1$ →

Model 3: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i$
restricció: $\beta_1 = 2\beta_2$ →

Model 4: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_4 x_{i4} + u_i$
restricció: $\beta_1 = 0 \quad \beta_2 + \beta_4 = 1$ →

Mètode de substitució

El **mètode de substitució** consisteix en rescriure el model integrant la restricció i després estimar el “**model restringit**” per MQO:

	model restringit?
Model 1: $y_i = \beta_0 + \beta_1 x_{i1} + u_i$ restricció: $\beta_0 = 2$	$\rightarrow (y_i - 2) = \beta_1 x_{i1} + u_i$
Model 2: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i$ restricció: $\beta_1 + \beta_2 = 1$	\rightarrow
Model 3: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i$ restricció: $\beta_1 = 2\beta_2$	\rightarrow
Model 4: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_4 x_{i4} + u_i$ restricció: $\beta_1 = 0 \quad \beta_2 + \beta_4 = 1$	\rightarrow

Mètode de substitució

El **mètode de substitució** consisteix en rescriure el model integrant la restricció i després estimar el “**model restringit**” per MQO:

	model restringit?
Model 1: $y_i = \beta_0 + \beta_1 x_{i1} + u_i$ restricció: $\beta_0 = 2$	$\rightarrow (y_i - 2) = \beta_1 x_{i1} + u_i$
Model 2: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i$ restricció: $\beta_1 + \beta_2 = 1$	$\rightarrow (y_i - x_{i2}) = \beta_0 + \beta_1(x_{i1} - x_{i2}) + u_i$
Model 3: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i$ restricció: $\beta_1 = 2\beta_2$	\rightarrow
Model 4: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_4 x_{i4} + u_i$ restricció: $\beta_1 = 0 \quad \beta_2 + \beta_4 = 1$	\rightarrow

Mètode de substitució

El **mètode de substitució** consisteix en rescriure el model integrant la restricció i després estimar el “**model restringit**” per MQO:

	model restringit?
Model 1: $y_i = \beta_0 + \beta_1 x_{i1} + u_i$ restricció: $\beta_0 = 2$	$\rightarrow (y_i - 2) = \beta_1 x_{i1} + u_i$
Model 2: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i$ restricció: $\beta_1 + \beta_2 = 1$	$\rightarrow (y_i - x_{i2}) = \beta_0 + \beta_1(x_{i1} - x_{i2}) + u_i$
Model 3: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i$ restricció: $\beta_1 = 2\beta_2$	$\rightarrow y_i = \beta_0 + \beta_1(x_{i1} + 2x_{i2}) + u_i$
Model 4: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_4 x_{i4} + u_i$ restricció: $\beta_1 = 0 \quad \beta_2 + \beta_4 = 1$	\rightarrow

Mètode de substitució

El **mètode de substitució** consisteix en rescriure el model integrant la restricció i després estimar el “**model restringit**” per MQO:

	model restringit?
Model 1: $y_i = \beta_0 + \beta_1 x_{i1} + u_i$ restricció: $\beta_0 = 2$	$\rightarrow (y_i - 2) = \beta_1 x_{i1} + u_i$
Model 2: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i$ restricció: $\beta_1 + \beta_2 = 1$	$\rightarrow (y_i - x_{i2}) = \beta_0 + \beta_1(x_{i1} - x_{i2}) + u_i$
Model 3: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i$ restricció: $\beta_1 = 2\beta_2$	$\rightarrow y_i = \beta_0 + \beta_1(x_{i1} + 2x_{i2}) + u_i$
Model 4: $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_4 x_{i4} + u_i$ restricció: $\beta_1 = 0 \quad \beta_2 + \beta_4 = 1$	$\rightarrow (y_i - x_{i4}) = \beta_0 + \beta_2(x_{i2} - x_{i4}) + u_i$

L'estimador mínim quadrat restringit (MQR)

L'estimador MQR és el que minimitza la suma de quadrats dels residus **subjecte a la restricció**:

$$\min_{\hat{\beta}} \hat{u}'\hat{u} = \min_{\hat{\beta}} (y - X\hat{\beta})'(y - X\hat{\beta})$$

s.a.

$$R\hat{\beta} = r.$$

I el resultat és:

$$\hat{\beta}_R = \hat{\beta} + (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1} (r - R\hat{\beta}).$$

Propietats de l'estimador MQR

Si les restriccions són certes ($R\beta = r$):

- $\mathbb{E}[\hat{\beta}_R] = \beta$.
- $\text{Var}(\hat{\beta}_R) = \sigma^2 ((X'X)^{-1} - (X'X)^{-1}R'[R(X'X)^{-1}R']^{-1}R(X'X)^{-1})$.

T3. EL MODEL DE REGRESSIÓ MÚLTIPLE: ESTIMACIÓ

- 1 El model de regressió amb K variables
- 2 L'estimador Mínim Quadrat Ordinari: MQO
- 3 Distribució de l'estimador MQO
- 4 L'estimador Mínim Quadrat Restringit: MQR
- 5 Aplicacions**
- 6 Variables fictícies

Introducció

A continuació ampliarem les nostres tres aplicacions de sempre per **il·lustrar** el que hem après en aquest tema.

Veurem com interpretar els resultats amb K **variables**.

A més, utilitzarem l'exemple de la funció de producció **Cobb-Douglas** per il·lustrar l'estimació amb **restriccions**.

I ampliarem l'exemple dels **salaris** per veure que passa si introduïm un **polinomi** de variables explicatives.

Noves variables per les nostres aplicacions

Model de **demanda de llet** (en milers d'ampolles):

- **Preu** unitari (en euros).
- Despesa en **publicitat** (en milers d'euros).
- Nombre d'**establiments** on es comercialitza (en milers).
- Quantitat de **calci** de la llet (en mg./100ml.).

Funció de producció **Cobb-Douglas** (versió agregada):

- **Capital** (en milers).
- **Treball** (en milers).

Salari:

- Anys d'**educació**.
- Anys d'**experiència**.
- Anys d'**experiència al quadrat**.

Demanda de llet: el model complet

Estem interessats en introduir més informació en el nostre model de demanda de llet. Les variables que considerarem són:

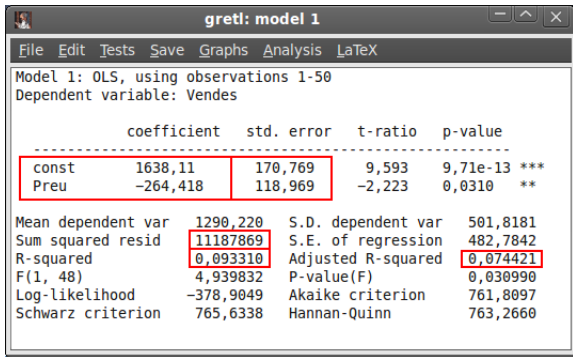
- **Publicitat**: fa augmentar la demanda de llet. La mesurarem com despesa en publicitat (milers d'euros).
- **Establiments**: a més establiments, més proximitat del producte, i menor cost d'adquirir-lo per part dels consumidors, per tant, augmenta la demanda.
- **Calci**: la qualitat de la llet depèn del calci. Per tant, també esperem que a més calci, major demanda de llet.

El **model complet** quedaria així:

$$Q_i = \beta_0 + \beta_1 P_i + \beta_2 Pub_i + \beta_4 Estab_i + \beta_5 Calci_i + u_i$$

Demanda de llet: resultats (I)

Així era el model on només incloïem el preu:



Model 1: OLS, using observations 1-50
Dependent variable: Vendes

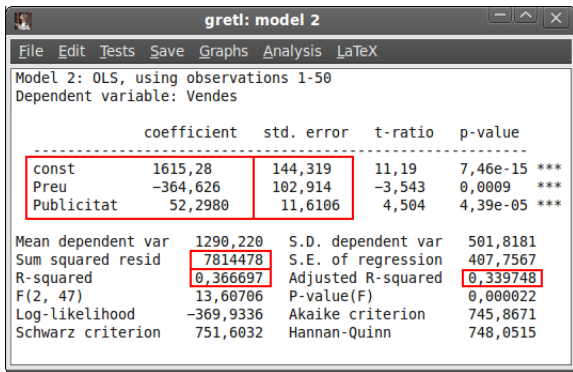
	coefficient	std. error	t-ratio	p-value
const	1638,11	170,769	9,593	9,71e-13 ***
Preu	-264,418	118,969	-2,223	0,0310 **

Mean dependent var	1290,220	S.D. dependent var	501,8181
Sum squared resid	11187869	S.E. of regression	482,7842
R-squared	0,093310	Adjusted R-squared	0,074421
F(1, 48)	4,939832	P-value(F)	0,030990
Log-likelihood	-378,9049	Akaike criterion	761,8097
Schwarz criterion	765,6338	Hannan-Quinn	763,2660

Interpretació?

Demanda de llet: resultats (II)

Anem a introduir les noves variables poc a poc. Primer **publicitat**:



The screenshot shows the gretl software interface with the following output:

Model 2: OLS, using observations 1-50
Dependent variable: Vendes

	coefficient	std. error	t-ratio	p-value
const	1615,28	144,319	11,19	7,46e-15 ***
Preu	-364,626	102,914	-3,543	0,0009 ***
Publicitat	52,2980	11,6106	4,504	4,39e-05 ***

Mean dependent var	1290,220	S.D. dependent var	501,8181
Sum squared resid	7814478	S.E. of regression	407,7567
R-squared	0,366697	Adjusted R-squared	0,339748
F(2, 47)	13,60706	P-value(F)	0,000022
Log-likelihood	-369,9336	Akaike criterion	745,8671
Schwarz criterion	751,6032	Hannan-Quinn	748,0515

Interpretació?

Què ha passat amb el coeficient del preu? Per què?

Com han canviat l' R^2 i l' \bar{R}^2 ?

Demanda de llet: resultats (III)

Després, establiments:

	coefficient	std. error	t-ratio	p-value
const	1179,62	116,377	10,14	2,64e-13 ***
Preu	-419,538	71,4707	-5,870	4,53e-07 ***
Publicitat	32,9252	8,45135	3,896	0,0003 ***
Establiments	10,7046	1,47655	7,250	3,85e-09 ***

Mean dependent var	1290,220	S.D. dependent var	501,8181
Sum squared resid	3647213	S.E. of regression	281,5799
R-squared	0,704422	Adjusted R-squared	0,685145
F(3, 46)	36,54240	P-value(F)	3,11e-12
Log-likelihood	-350,8832	Akaike criterion	709,7664
Schwarz criterion	717,4145	Hannan-Quinn	712,6788

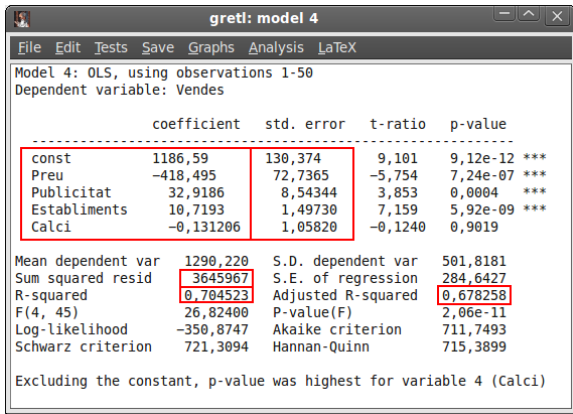
Interpretació?

Què ha passat amb els coeficients del preu i publicitat? Per què?

Com han canviat l' R^2 i l' \bar{R}^2 ?

Demanda de llet: resultats (IV)

Finalment, calci:



The screenshot shows the gret! software interface for 'model 4'. The dependent variable is 'Vendes'. The regression results are as follows:

	coefficient	std. error	t-ratio	p-value
const	1186,59	130,374	9,101	9,12e-12 ***
Preu	-418,495	72,7365	-5,754	7,24e-07 ***
Publicitat	32,9186	8,54344	3,853	0,0004 ***
Establiments	10,7193	1,49730	7,159	5,92e-09 ***
Calci	-0,131206	1,05820	-0,1240	0,9019

Mean dependent var	1290,220	S.D. of dependent var	501,8181
Sum squared resid	3645967	S.E. of regression	284,6427
R-squared	0,704523	Adjusted R-squared	0,678258
F(4, 45)	26,82400	P-value(F)	2,06e-11
Log-likelihood	-350,8747	Akaike criterion	711,7493
Schwarz criterion	721,3094	Hannan-Quinn	715,3899

Excluding the constant, p-value was highest for variable 4 (Calci)

Interpretació?

Què ha passat ara amb els coeficients anteriors? Per què?

Com han canviat ara l' R^2 i l' \bar{R}^2 ?

Funció de producció Cobb-Douglas amb dades agregades

Ara volem estimar la funció de producció Cobb-Douglas amb **dades agregades**. Per tant,

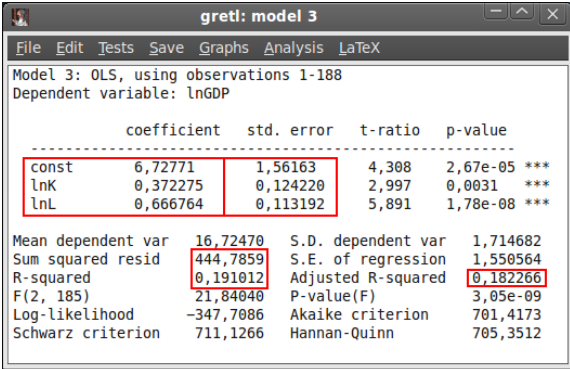
$$Y = AK^\alpha L^{1-\alpha} \Rightarrow \ln Y_i = \beta_0 + \beta_1 \ln K_i + \beta_2 \ln L_i + u_i,$$

on ara les variables són **output** (Y_i , en milions de dòlars), **capital** (K_i , en milions de dòlars) i **treball** (L_i , en milions de treballadors).

El model, però, ens imposa una restricció:

$$\beta_2 = 1 - \beta_1 \Leftrightarrow \beta_1 + \beta_2 = 1$$

Cobb-Douglas amb dades agregades: estimació no restringida



gretl: model 3

File Edit Tests Save Graphs Analysis LaTeX

Model 3: OLS, using observations 1-188
Dependent variable: lnGDP

	coefficient	std. error	t-ratio	p-value	
const	6,72771	1,56163	4,308	2,67e-05	***
lnK	0,372275	0,124220	2,997	0,0031	***
lnL	0,666764	0,113192	5,891	1,78e-08	***

Mean dependent var	16,72470	S.D. dependent var	1,714682
Sum squared resid	444,7859	S.E. of regression	1,550564
R-squared	0,191012	Adjusted R-squared	0,182266
F(2, 185)	21,84040	P-value(F)	3,05e-09
Log-likelihood	-347,7086	Akaike criterion	701,4173
Schwarz criterion	711,1266	Hannan-Quinn	705,3512

Interpretació?

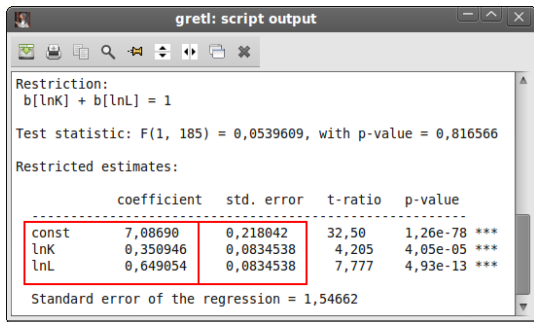
Quin és el valor de $\hat{\beta}_1 + \hat{\beta}_2$?

Cobb-Douglas amb dades agregades: estimació per MQR

Gretl permet l'estimació del model amb restriccions per MQR.

No ho veurem perquè sempre podem estimar el model pel mètode de substitució.

En el nostre cas, el resultat d'estimar el model per MQR és:



Restriction:
 $b[\ln K] + b[\ln L] = 1$

Test statistic: $F(1, 185) = 0,0539609$, with p-value = $0,816566$

Restricted estimates:

	coefficient	std. error	t-ratio	p-value
const	7,08690	0,218042	32,50	1,26e-78 ***
lnK	0,350946	0,0834538	4,205	4,05e-05 ***
lnL	0,649054	0,0834538	7,777	4,93e-13 ***

Standard error of the regression = 1,54662

Com són els errors estàndard comparats amb els d'abans?

Cobb-Douglas amb dades agregades: mètode de substitució (I)

Quin seria el **model restringit**?

$$\ln Y_i = \beta_0 + \beta_1 \ln K_i + (1 - \beta_1) \ln L_i + u_i$$

Cobb-Douglas amb dades agregades: mètode de substitució (I)

Quin seria el **model restringit**?

$$\ln Y_i = \beta_0 + \beta_1 \ln K_i + (1 - \beta_1) \ln L_i + u_i$$

$$\ln Y_i = \beta_0 + \beta_1 \ln K_i + \ln L_i - \beta_1 \ln L_i + u_i$$

Cobb-Douglas amb dades agregades: mètode de substitució (I)

Quin seria el **model restringit**?

$$\ln Y_i = \beta_0 + \beta_1 \ln K_i + (1 - \beta_1) \ln L_i + u_i$$

$$\ln Y_i = \beta_0 + \beta_1 \ln K_i + \ln L_i - \beta_1 \ln L_i + u_i$$

$$(\ln Y_i - \ln L_i) = \beta_0 + \beta_1(\ln K_i - \ln L_i) + u_i$$

Cobb-Douglas amb dades agregades: mètode de substitució (I)

Quin seria el **model restringit**?

$$\ln Y_i = \beta_0 + \beta_1 \ln K_i + (1 - \beta_1) \ln L_i + u_i$$

$$\ln Y_i = \beta_0 + \beta_1 \ln K_i + \ln L_i - \beta_1 \ln L_i + u_i$$

$$(\ln Y_i - \ln L_i) = \beta_0 + \beta_1 (\ln K_i - \ln L_i) + u_i$$

$$\ln Y_i^* = \beta_0 + \beta_1 \ln K_i^* + u_i$$

Cobb-Douglas amb dades agregades: mètode de substitució (I)

Quin seria el **model restringit**?

$$\ln Y_i = \beta_0 + \beta_1 \ln K_i + (1 - \beta_1) \ln L_i + u_i$$

$$\ln Y_i = \beta_0 + \beta_1 \ln K_i + \ln L_i - \beta_1 \ln L_i + u_i$$

$$(\ln Y_i - \ln L_i) = \beta_0 + \beta_1 (\ln K_i - \ln L_i) + u_i$$

$$\ln Y_i^* = \beta_0 + \beta_1 \ln K_i^* + u_i$$

A què són iguals Y_i^* i K_i^* ? Ens resulta familiar?

Aquest mètode ens donarà **exactament els mateixos resultats** que l'estimació per MQR.

Cobb-Douglas amb dades agregades: mètode de substitució (II)

Per estimar-lo:

- primer hem de **generar** les noves variables $\ln Y_i^*$ i $\ln K_i^*$.
- i després **estimar** la regressió com sempre hem fet.

gret!: model 1

File Edit Tests Save Graphs Analysis LaTeX

Model 1: OLS, using observations 1-188
Dependent variable: lnGDPstar

	coefficient	std. error	t-ratio	p-value
const	7,08690	0,218042	32,50	1,26e-78 ***
lnKstar	0,350946	0,0834538	4,205	4,05e-05 ***

Mean dependent var	6,302204	S.D. dependent var	1,614137
Sum squared resid	444,9157	S.E. of regression	1,546616
R-squared	0,086822	Adjusted R-squared	0,081913
F(1, 186)	17,68429	P-value(F)	0,000040
Log-likelihood	-347,7361	Akaike criterion	699,4721
Schwarz criterion	705,9450	Hannan-Quinn	702,0947

Com podem recuperar el valor de $\hat{\beta}_2$?

El model del salari ampliat: l'equació de Mincer

El **model de Mincer** ens diu que els salaris venen explicats per l'educació i l'experiència de la següent forma:

$$W_i = \omega_0 e^{\omega_1 Edu_i + \omega_2 Exp_i + \omega_3 Exp_i^2},$$

on W és el **salari**, Edu són els anys d'**educació** i Exp són els anys d'**experiència**.

Per tant, el model que volem estimar serà:


$$\ln W_i = \beta_0 + \beta_1 Edu_i + \beta_2 Exp_i + \beta_4 Exp_i^2 + u_i$$

és un model de regressió lineal?


L'equació de Mincer: *la relació entre salaris i experiència (I)*



L'equació de Mincer: la relació entre salaris i experiència (II)

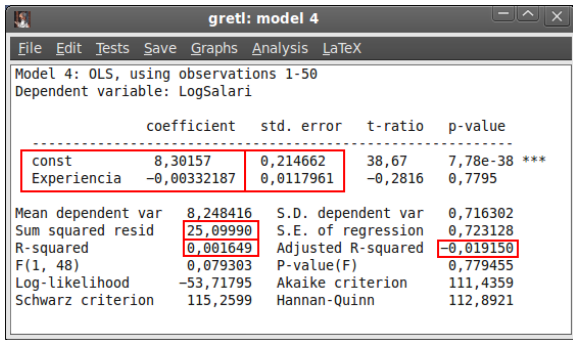


L'equació de Mincer: *la relació entre salaris i experiència (III)*



L'equació de Mincer: resultats (I)

Abans d'estimar el model, anem a veure més precisament quina és la relació entre experiència i el salari:



gret!: model 4

File Edit Tests Save Graphs Analysis LaTeX

Model 4: OLS, using observations 1-50
Dependent variable: LogSalari

	coefficient	std. error	t-ratio	p-value
const	8,30157	0,214662	38,67	7,78e-38 ***
Experiencia	-0,00332187	0,0117961	-0,2816	0,7795

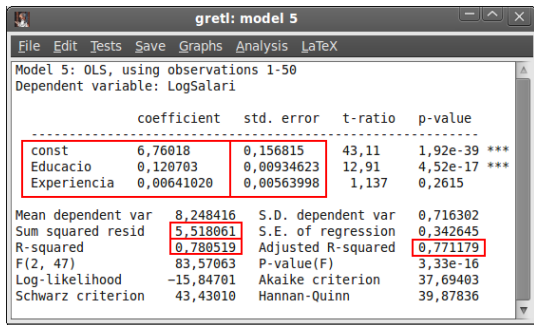
Mean dependent var	8,248416	S.D. dependent var	0,716302
Sum squared resid	25,09990	S.E. of regression	0,723128
R-squared	0,001649	Adjusted R-squared	-0,019150
F(1, 48)	0,079303	P-value(F)	0,779455
Log-likelihood	-53,71795	Akaike criterion	111,4359
Schwarz criterion	115,2599	Hannan-Quinn	112,8921

Interpretació?

L'equació de Mincer: resultats (II)

Possible explicació d'aquest vincle tan dèbil, **dos efectes**:

- Més experiència \Rightarrow més productivitat \Rightarrow més salari
- Més experiència \Rightarrow menys educació \Rightarrow menys salari



gret! model 5

File Edit Tests Save Graphs Analysis LaTeX

Model 5: OLS, using observations 1-50
Dependent variable: LogSalari

	coeficient	std. error	t-ratio	p-value
const	6,76018	0,156815	43,11	1,92e-39 ***
Educacio	0,120703	0,00934623	12,91	4,52e-17 ***
Experiencia	0,00641020	0,00563998	1,137	0,2615

Mean dependent var	8,248416	S.D. dependent var	0,716302
Sum squared resid	5,518061	S.E. of regression	0,342645
R-squared	0,780519	Adjusted R-squared	0,771179
F(2, 47)	83,57063	P-value(F)	3,33e-16
Log-likelihood	-15,84701	Akaike criterion	37,69403
Schwarz criterion	43,43010	Hannan-Quinn	39,87836

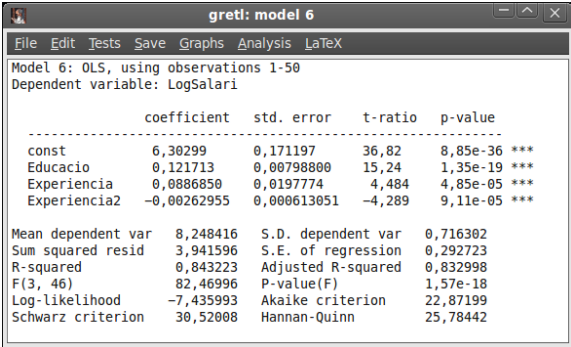
Interpretació?

Podem concloure que l'experiència té un efecte residual?

L'equació de Mincer: resultats (III)

Podem estimar l'equació de Mincer (completa):

$$\ln W_i = \beta_0 + \beta_1 Edu_i + \beta_2 Exp_i + \beta_4 Exp_i^2 + u_i$$



	coefficient	std. error	t-ratio	p-value
const	6,30299	0,171197	36,82	8,85e-36 ***
Educacio	0,121713	0,00798800	15,24	1,35e-19 ***
Experiencia	0,0886850	0,0197774	4,484	4,85e-05 ***
Experiencia2	-0,00262955	0,000613051	-4,289	9,11e-05 ***
Mean dependent var	8,248416	S.D. dependent var	0,716302	
Sum squared resid	3,941596	S.E. of regression	0,292723	
R-squared	0,843223	Adjusted R-squared	0,832998	
F(3, 46)	82,46996	P-value(F)	1,57e-18	
Log-likelihood	-7,435993	Akaike criterion	22,87199	
Schwarz criterion	30,52008	Hannan-Quinn	25,78442	

Interpretació?

T3. EL MODEL DE REGRESSIÓ MÚLTIPLE: ESTIMACIÓ

- 1 El model de regressió amb K variables
- 2 L'estimador Mínim Quadrat Ordinari: MQO
- 3 Distribució de l'estimador MQO
- 4 L'estimador Mínim Quadrat Restringit: MQR
- 5 Aplicacions
- 6** Variables fictícies

Motivació

No sempre volem considerar variables **quantitatives** (preu, capital, anys d'educació,...) en el nostre anàlisi.

A vegades ens pot interessar saber quin és l'efecte d'una variable **qualitativa** sobre la nostra variable dependent:

- Com afecta el **Tetra Brick** a les vendes de llet
- Com canvia l'output per capita en un país **democràtic** si el comparem amb un país autocràtic
- Quin és el diferencial salarial entre **homes** i **dones**

Variables fictícies

Per poder fer aquest anàlisi utilitzarem **variables fictícies**, d_i :

- Si la observació **compleix** la característica, $d_i = 1$:
 - L'empresa comercialitza la seva llet en Tetra Brick
 - El país gaudeix d'una democràcia
 - L'individu és una dona
- Si **no** la compleix, $d_i = 0$.

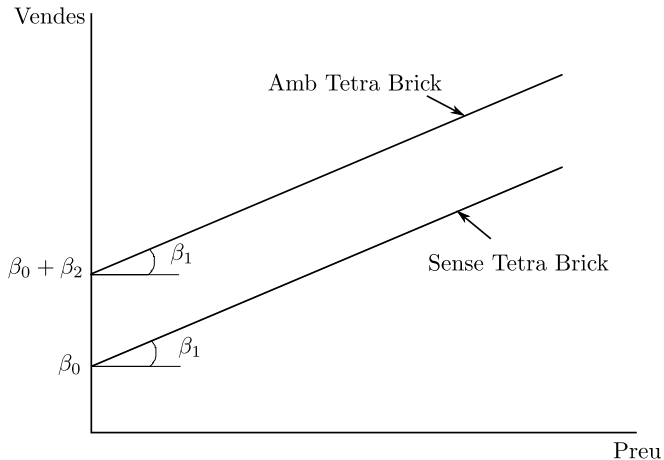
El Tetra-Brick i les vendes de llet (I)

Al model de demanda de llet simple (vendes-preu) li afegirem ara una variable TB_i :

$$Vendes_i = \beta_1 + \beta_2 Preu_i + \beta_3 TB_i + u_i$$

- Si l'empresa ven en Tetra Brick, $TB_i = 1$
- En cas contrari, $TB_i = 0$

Interpretació gràfica



El Tetra Brick i les vendes de llet (II)

En el model anterior estavem analitzant en quant augmenten les vendes (donat un preu).

Poster la llet en Tetra Brick és un “producte diferent” a la llet en ampolla, i per això tota **la demanda és diferent**:


$$Vendes_i = \beta_1^{TB} + \beta_2^{TB} Preu_i + u_i \quad (\text{TetraBrick})$$

$$Vendes_i = \beta_1^A + \beta_2^A Preu_i + u_i \quad (\text{Ampolla})$$


Això es pot escriure com:

$$Vendes_i = \beta_1 + \beta_2 Preu_i + \beta_3 TB_i + \beta_4 Preu_i TB_i + u_i$$

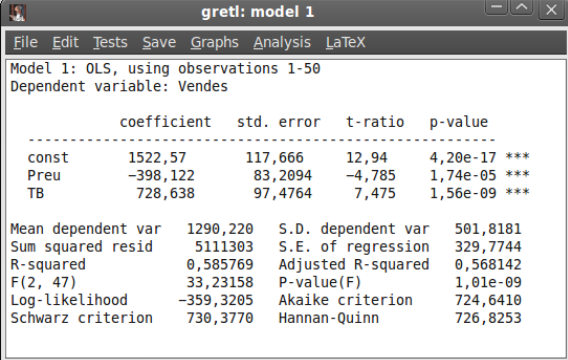
Interpretació gràfica



Aplicacions: Demanda de llet (I)



Aplicacions: Demanda de llet (II)



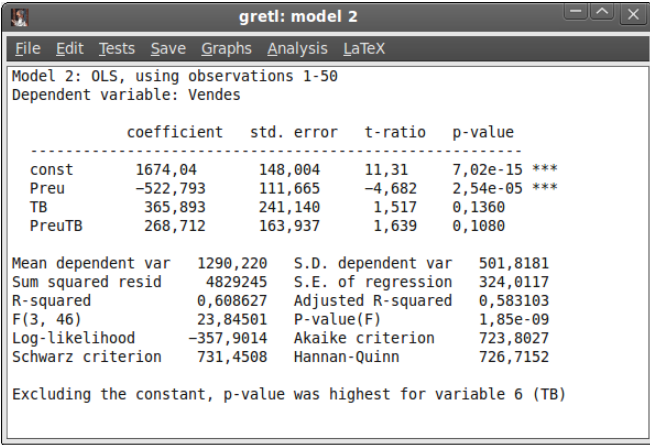
The screenshot shows a window titled "gretl: model 1" with a menu bar containing "File", "Edit", "Tests", "Save", "Graphs", "Analysis", and "LaTeX". The main content area displays the following text:

Model 1: OLS, using observations 1-50
Dependent variable: Vendes

	coefficient	std. error	t-ratio	p-value
const	1522,57	117,666	12,94	4,20e-17 ***
Preu	-398,122	83,2094	-4,785	1,74e-05 ***
TB	728,638	97,4764	7,475	1,56e-09 ***

Mean dependent var	1290,220	S.D. dependent var	501,8181
Sum squared resid	5111303	S.E. of regression	329,7744
R-squared	0,585769	Adjusted R-squared	0,568142
F(2, 47)	33,23158	P-value(F)	1,01e-09
Log-likelihood	-359,3205	Akaike criterion	724,6410
Schwarz criterion	730,3770	Hannan-Quinn	726,8253

Aplicacions: Demanda de llet (III)



The screenshot shows a window titled "gretl: model 2" with a menu bar containing "File", "Edit", "Tests", "Save", "Graphs", "Analysis", and "LaTeX". The main content area displays the following text:


Model 2: OLS, using observations 1-50
Dependent variable: Vendes

	coefficient	std. error	t-ratio	p-value
const	1674,04	148,004	11,31	7,02e-15 ***
Preu	-522,793	111,665	-4,682	2,54e-05 ***
TB	365,893	241,140	1,517	0,1360
PreuTB	268,712	163,937	1,639	0,1080


Mean dependent var	1290,220	S.D. dependent var	501,8181
Sum squared resid	4829245	S.E. of regression	324,0117
R-squared	0,608627	Adjusted R-squared	0,583103
F(3, 46)	23,84501	P-value(F)	1,85e-09
Log-likelihood	-357,9014	Akaike criterion	723,8027
Schwarz criterion	731,4508	Hannan-Quinn	726,7152

Excluding the constant, p-value was highest for variable 6 (TB)

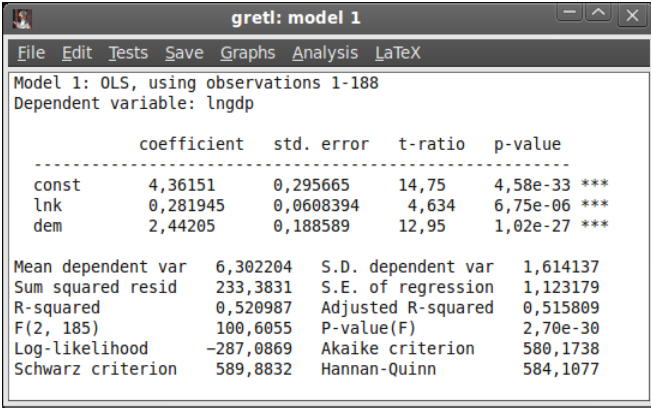
Aplicacions: Demanda de llet (IV)



Aplicacions: Cobb-Douglas (I)



Aplicacions: Cobb-Douglas (II)



Model 1: OLS, using observations 1-188
Dependent variable: lngdp

	coefficient	std. error	t-ratio	p-value	
const	4,36151	0,295665	14,75	4,58e-33	***
lnk	0,281945	0,0608394	4,634	6,75e-06	***
dem	2,44205	0,188589	12,95	1,02e-27	***

Mean dependent var	6,302204	S.D. dependent var	1,614137
Sum squared resid	233,3831	S.E. of regression	1,123179
R-squared	0,520987	Adjusted R-squared	0,515809
F(2, 185)	100,6055	P-value(F)	2,70e-30
Log-likelihood	-287,0869	Akaike criterion	580,1738
Schwarz criterion	589,8832	Hannan-Quinn	584,1077

Aplicacions: Cobb-Douglas (III)

gretl: model 2

File Edit Tests Save Graphs Analysis LaTeX


Model 2: OLS, using observations 1-188
Dependent variable: lngdp

	coefficient	std. error	t-ratio	p-value	
const	4,29544	0,331935	12,94	1,18e-27	***
lnk	0,296299	0,0690952	4,288	2,90e-05	***
dem	2,75429	0,731875	3,763	0,0002	***
lnkdem	-0,0648615	0,146877	-0,4416	0,6593	

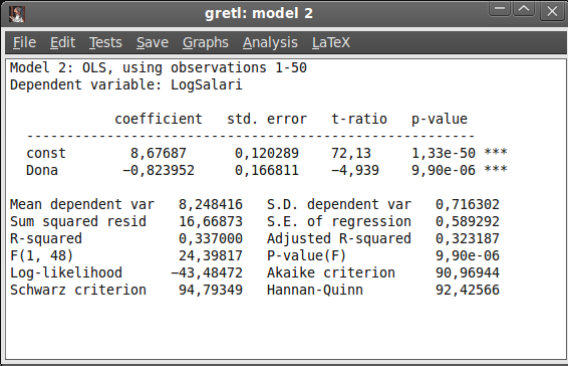
Mean dependent var	6,302204	S.D. dependent var	1,614137
Sum squared resid	233,1360	S.E. of regression	1,125630
R-squared	0,521494	Adjusted R-squared	0,513693
F(3, 184)	66,84351	P-value(F)	2,80e-29
Log-likelihood	-286,9874	Akaike criterion	581,9747
Schwarz criterion	594,9205	Hannan-Quinn	587,2198

Excluding the constant, p-value was highest for variable 7 (lnkdem)

Aplicacions: Cobb-Douglas (IV)



Aplicacions: Salaris (I)



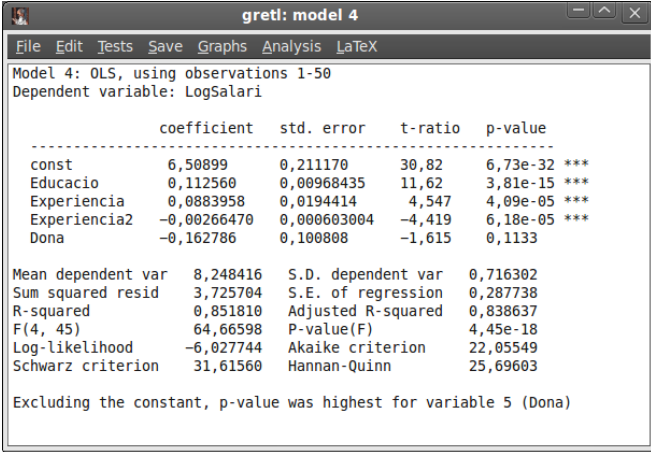
The screenshot shows the 'gretl: model 2' window. The title bar includes a small icon, the text 'gretl: model 2', and standard window controls (minimize, maximize, close). The menu bar contains 'File', 'Edit', 'Tests', 'Save', 'Graphs', 'Analysis', and 'LaTeX'. The main text area displays the following information:

Model 2: OLS, using observations 1-50
Dependent variable: LogSalari

	coefficient	std. error	t-ratio	p-value
const	8,67687	0,120289	72,13	1,33e-50 ***
Dona	-0,823952	0,166811	-4,939	9,90e-06 ***

Mean dependent var	8,248416	S.D. dependent var	0,716302
Sum squared resid	16,66873	S.E. of regression	0,589292
R-squared	0,337000	Adjusted R-squared	0,323187
F(1, 48)	24,39817	P-value(F)	9,90e-06
Log-likelihood	-43,48472	Akaike criterion	90,96944
Schwarz criterion	94,79349	Hannan-Quinn	92,42566

Aplicacions: Salaris (II)



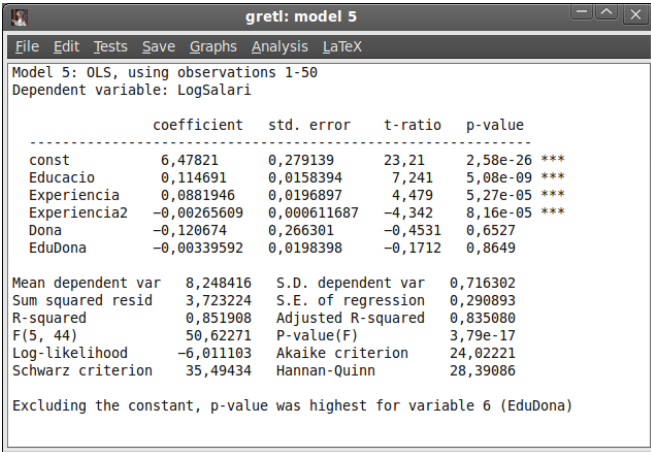
The screenshot shows a window titled "gretl: model 4" with a menu bar (File, Edit, Tests, Save, Graphs, Analysis, LaTeX). The main text reads "Model 4: OLS, using observations 1-50" and "Dependent variable: LogSalari". Below this is a table of regression coefficients, standard errors, t-ratios, and p-values. A dashed line separates the coefficient table from the summary statistics. The summary statistics include Mean dependent var, Sum squared resid, R-squared, F(4, 45), Log-likelihood, Schwarz criterion, S.D. dependent var, S.E. of regression, Adjusted R-squared, P-value(F), Akaike criterion, and Hannan-Quinn. At the bottom, it states "Excluding the constant, p-value was highest for variable 5 (Dona)".

	coefficient	std. error	t-ratio	p-value	

const	6,50899	0,211170	30,82	6,73e-32	***
Educacio	0,112560	0,00968435	11,62	3,81e-15	***
Experiencia	0,0883958	0,0194414	4,547	4,09e-05	***
Experiencia2	-0,00266470	0,000603004	-4,419	6,18e-05	***
Dona	-0,162786	0,100808	-1,615	0,1133	
Mean dependent var	8,248416	S.D. dependent var	0,716302		
Sum squared resid	3,725704	S.E. of regression	0,287738		
R-squared	0,851810	Adjusted R-squared	0,838637		
F(4, 45)	64,66598	P-value(F)	4,45e-18		
Log-likelihood	-6,027744	Akaike criterion	22,05549		
Schwarz criterion	31,61560	Hannan-Quinn	25,69603		

Excluding the constant, p-value was highest for variable 5 (Dona)

Aplicacions: Salaris (III)



The screenshot shows a window titled "gretl: model 5" with a menu bar (File, Edit, Tests, Save, Graphs, Analysis, LaTeX). The main text reads: "Model 5: OLS, using observations 1-50" and "Dependent variable: LogSalari". Below this is a table of regression coefficients, standard errors, t-ratios, and p-values. The table is followed by summary statistics and a note about excluding the constant.

	coefficient	std. error	t-ratio	p-value	
const	6,47821	0,279139	23,21	2,58e-26	***
Educacio	0,114691	0,0158394	7,241	5,08e-09	***
Experiencia	0,0881946	0,0196897	4,479	5,27e-05	***
Experiencia2	-0,00265609	0,000611687	-4,342	8,16e-05	***
Dona	-0,120674	0,266301	-0,4531	0,6527	
EduDona	-0,00339592	0,0198398	-0,1712	0,8649	

Mean dependent var	8,248416	S.D. dependent var	0,716302
Sum squared resid	3,723224	S.E. of regression	0,290893
R-squared	0,851908	Adjusted R-squared	0,835080
F(5, 44)	50,62271	P-value(F)	3,79e-17
Log-likelihood	-6,011103	Akaike criterion	24,02221
Schwarz criterion	35,49434	Hannan-Quinn	28,39086

Excluding the constant, p-value was highest for variable 6 (EduDona)

Aplicacions: Salaris (IV)

gretl: model 7

File Edit Tests Save Graphs Analysis LaTeX

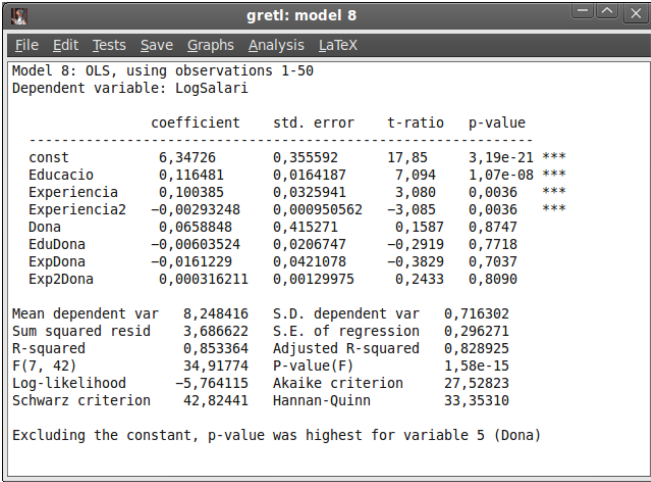
Model 7: OLS, using observations 1-50
Dependent variable: LogSalari

	coefficient	std. error	t-ratio	p-value	
const	6,44303	0,243116	26,50	1,10e-28	***
Educacio	0,112724	0,00976332	11,55	6,62e-15	***
Experiencia	0,0943952	0,0223194	4,229	0,0001	***
Experiencia2	-0,00276689	0,000634358	-4,362	7,67e-05	***
Dona	-0,0733810	0,188979	-0,3883	0,6997	
ExpDona	-0,00555626	0,00990335	-0,5610	0,5776	

Mean dependent var	8,248416	S.D. dependent var	0,716302
Sum squared resid	3,699239	S.E. of regression	0,289955
R-squared	0,852862	Adjusted R-squared	0,836142
F(5, 44)	51,00799	P-value(F)	3,29e-17
Log-likelihood	-5,849531	Akaike criterion	23,69906
Schwarz criterion	35,17120	Hannan-Quinn	28,06772

Excluding the constant, p-value was highest for variable 5 (Dona)

Aplicacions: Salaris (V)



gret! model 8

File Edit Tests Save Graphs Analysis LaTeX

Model 8: OLS, using observations 1-50
Dependent variable: LogSalari

	coefficient	std. error	t-ratio	p-value	
const	6,34726	0,355592	17,85	3,19e-21	***
Educacio	0,116481	0,0164187	7,094	1,07e-08	***
Experiencia	0,100385	0,0325941	3,080	0,0036	***
Experiencia2	-0,00293248	0,000950562	-3,085	0,0036	***
Dona	0,0658848	0,415271	0,1587	0,8747	
EduDona	-0,00603524	0,0206747	-0,2919	0,7718	
ExpDona	-0,0161229	0,0421078	-0,3829	0,7037	
Exp2Dona	0,000316211	0,00129975	0,2433	0,8090	
Mean dependent var	8,248416	S.D. dependent var	0,716302		
Sum squared resid	3,686622	S.E. of regression	0,296271		
R-squared	0,853364	Adjusted R-squared	0,828925		
F(7, 42)	34,91774	P-value(F)	1,58e-15		
Log-likelihood	-5,764115	Akaike criterion	27,52823		
Schwarz criterion	42,82441	Hannan-Quinn	33,35310		

Excluding the constant, p-value was highest for variable 5 (Dona)