

Regressione lineare semplice e multipla

Prof. G. Scandurra

Regressione lineare

In molte applicazioni si è interessati a valutare se una variabile (dipendente) può essere in relazione funzionale con una o più variabili indipendenti.

Nel primo caso (una sola variabile indipendente) si parla di regressione semplice.

Nel secondo caso (più variabili indipendenti) si parla di regressione multipla. In generale:

$$y = f(x_1, x_2, \dots, x_n)$$

Se la funzione f è di primo grado, si parla di regressione lineare.

La regressione lineare semplice

$$y = \alpha + \beta x$$

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_q x_q$$

$$y = a + bx$$

$$y = b_0 + b_1 x_1 + \dots + b_q x_q$$

Intercetta

Coefficiente
angolare

**Parametri da calcolare
nella Popolazione nel caso
di 1 o più variabili
indipendenti**

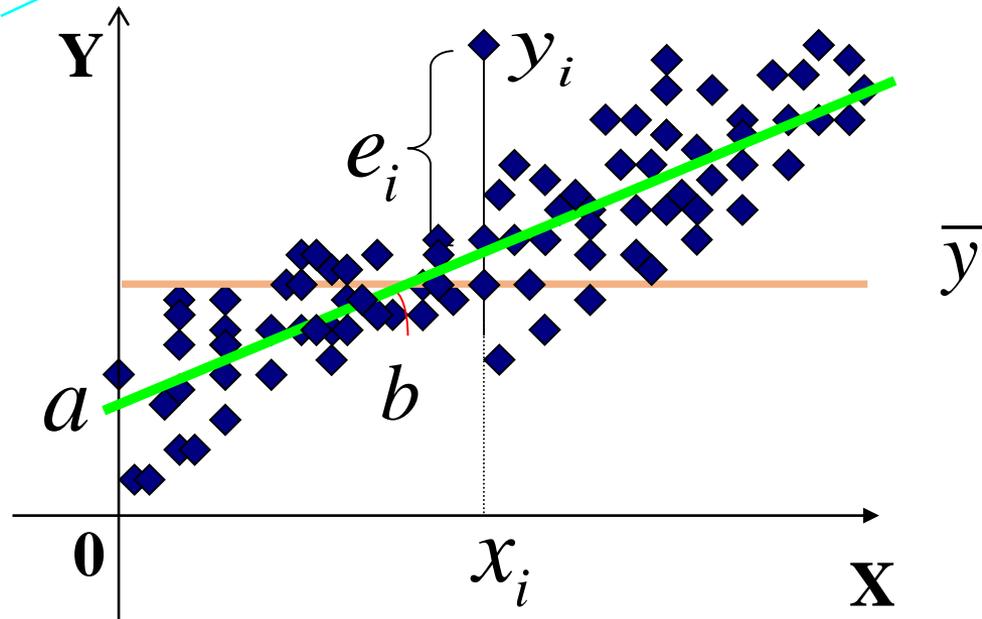
**Parametri da calcolare
nel campione nel caso
di 1 o più variabili
indipendenti**

La regressione lineare semplice

Valore vero $\rightarrow y_i = a + bx_i + e_i$

Valore calcolato sulla retta = \hat{y}_i

Scarto o errore o residuo



La regressione lineare: le ipotesi

1) $y = a + bx + \varepsilon$

2) $E(\varepsilon) = 0$

3) $Var(\varepsilon) = cost < \infty$

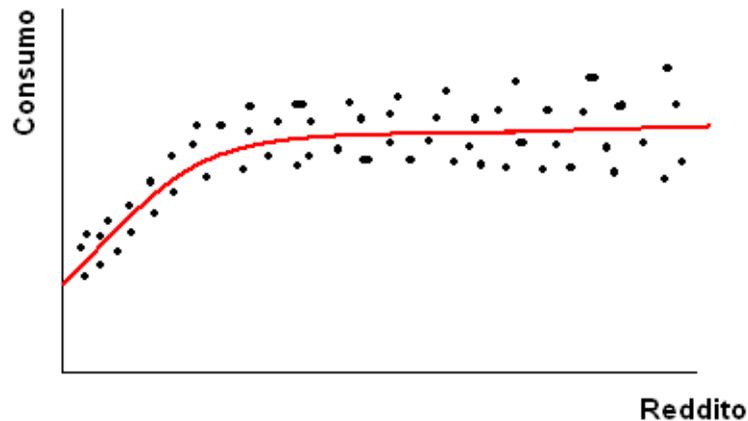
4) $Cov(\varepsilon_i, \varepsilon_j) = 0$

6) $Cov(\varepsilon, x) = 0$

7) *Assenza di collinearità perfetta tra le x (se più di una)*

} 5) $\varepsilon = N(0, \sigma) ??$

IMPORTANTE



Caso di eteroschedasticità

La regressione lineare: le ipotesi

$$y = \alpha + \beta x_1 + \varepsilon$$

Modello stimato

$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \varepsilon^*$$

Modello "vero" con una probabile relazione sussistente tra x_1 e x_2

$$\text{cov}(x_1, x_2) \neq 0$$

Varianza vera di y

$$\text{var}(y) = \beta_1 \text{var}(x_1) + \beta_2 \text{var}(x_2) + \text{var}(\varepsilon^*)$$

Per assumere lo stesso valore nel modello stimato, deve necessariamente essere:

$$\text{var}(y) = \beta \text{var}(x_1) + \text{var}(\varepsilon) + \text{cov}(x_1, \varepsilon)$$

La regressione lineare: la verifica delle ipotesi

ALCUNI PRINCIPI BASILARI PRIMA DI COMINCIARE

I programmi informatici sono strumenti utilissimi che ci risparmiano calcoli lunghi, noiosi e diminuiscono la probabilità di commettere errori

I programmi informatici senza l'intelligenza umana che li usa e li interpreta, non servono a nulla

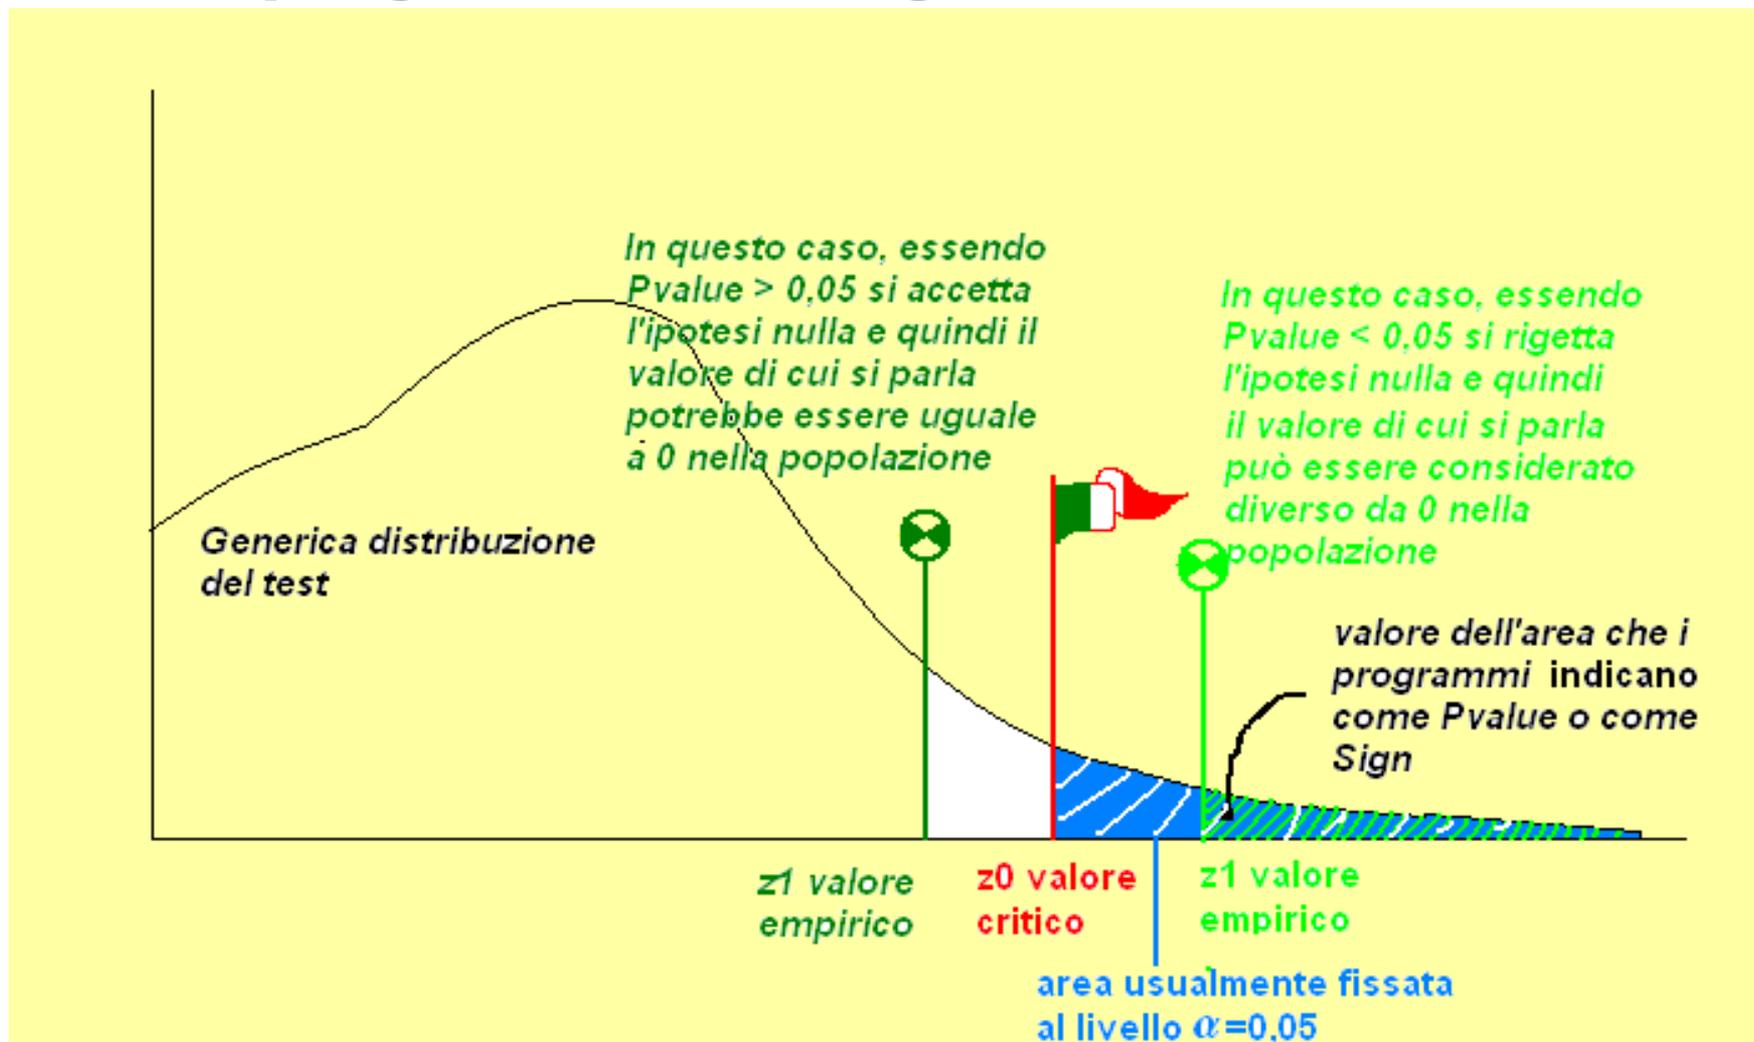
Una volta che programmi hanno effettuato i calcoli della regressione deve intervenire lo statistico per verificare il modello sperimentato

Ogni modello, anche il più bislacco, darà dei risultati che a prima vista potrebbero anche sembrare accettabili

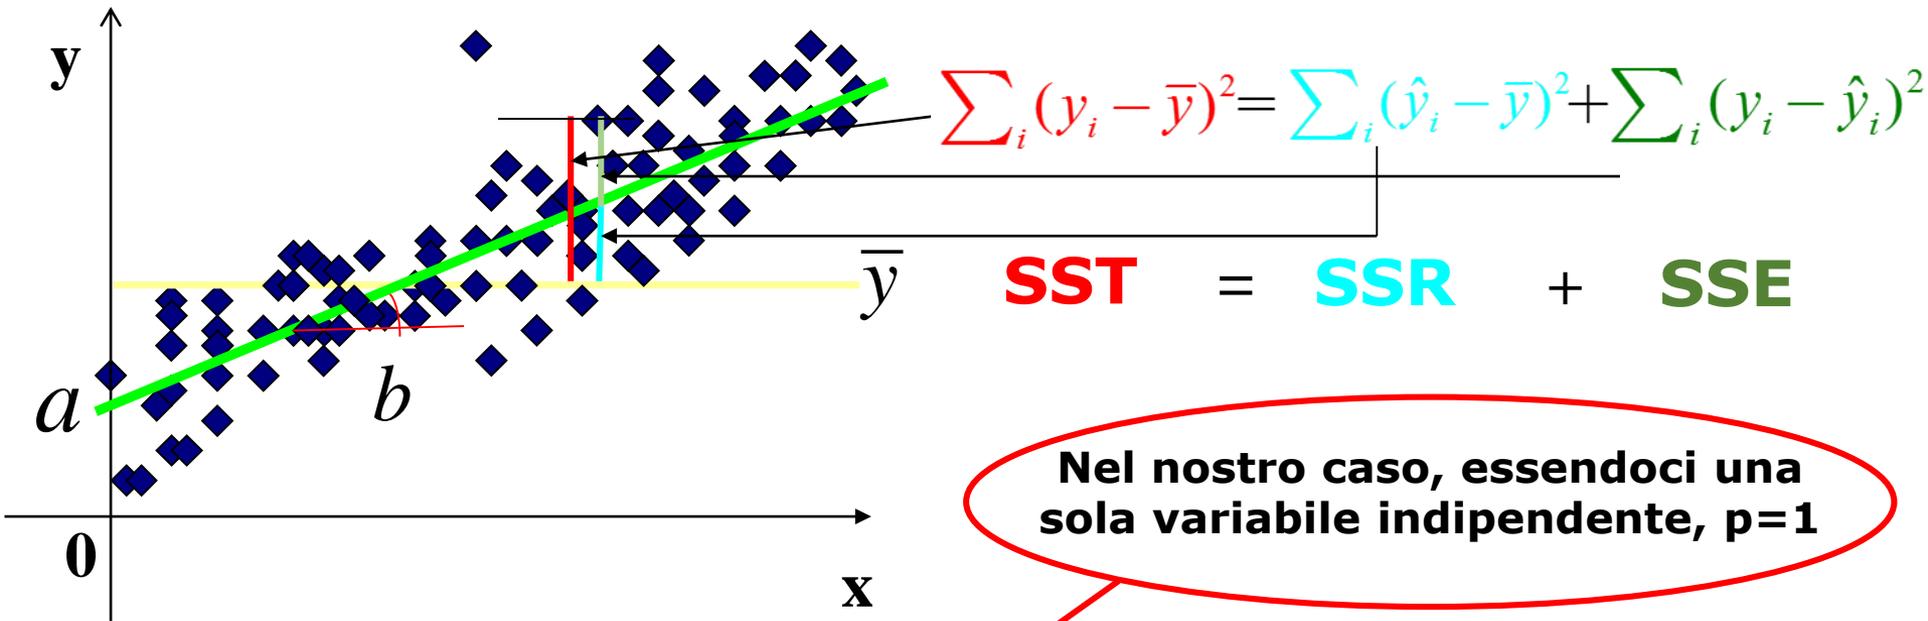
E' DI VITALE IMPORTANZA CHE, A POSTERIORI, SI VERIFICHINO SE LE IPOTESI CHE FANNO DA BASE AL MODELLO SIANO STATE RISPETTATE. E' INDISPENSABILE TROVARE LE LORO TRACCE NEI RISULTATI FORNITI DAL PROGRAMMA!!

La regressione lineare

UNA QUESTIONE PRELIMINARE: che intendono i programmi con Sign o con Pvalue



La regressione lineare



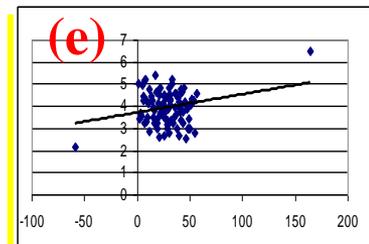
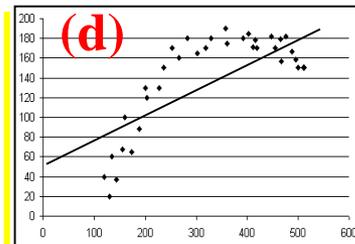
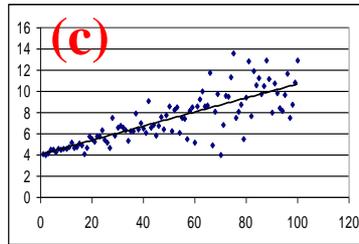
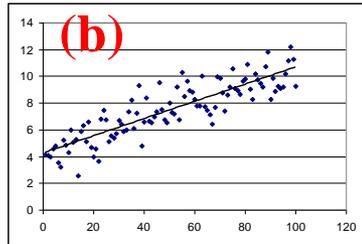
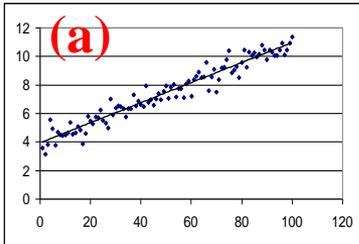
$$R^2 = \frac{SSR}{SST}$$

$$F = \frac{\frac{SSR}{p}}{\frac{SSE}{n-p-1}}$$

$$DW = \frac{\sum_{i=2}^n (e_i - e_{i-1})^2}{\sum_{i=2}^n (e_i)^2}$$

$$t_{\beta} = \frac{\hat{\beta}}{sb_{\beta}}$$

La regressione lineare semplice



F 1524,046 0,000
a 3,920 0,000
b 0,070 0,000
R² 0,940
DW 2,002

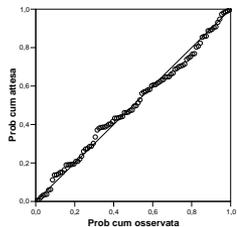
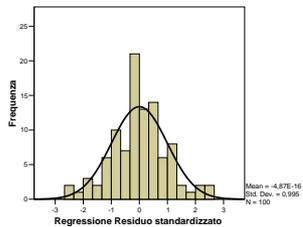
F 298,305 0,000
a 4,247 0,000
b 0,064 0,000
R² 0,753
DW 1,989

F 173,175 0,000
a 4,025 0,000
b 0,066 0,000
R² 0,639
DW 1,041

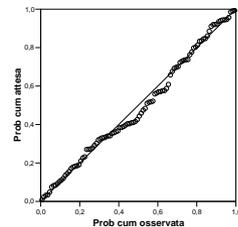
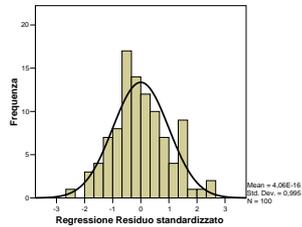
F 45,81 0,000
a 48,058 0,000
b 0,283 0,000
R² 0,581
DW 0,338

F 5,797 0,018
a 3,697 0,000
b 0,008 0,038
R² 0,057
DW 2,001

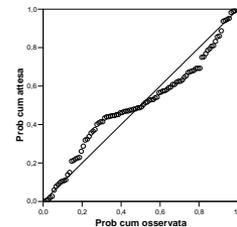
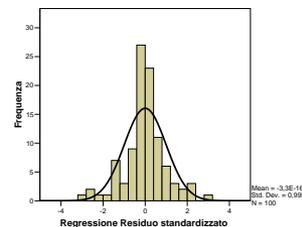
Istogramma



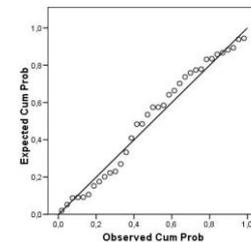
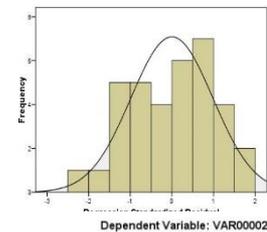
Istogramma



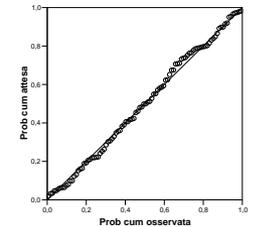
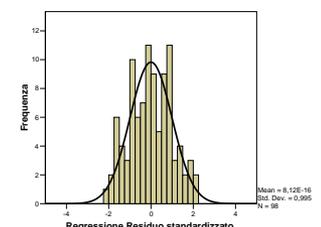
Istogramma



Istogram



Istogramma



La regressione lineare multipla

$$y_1 = \beta_0 + \beta_1 x_{11} + \beta_2 x_{12} + \dots + \beta_p x_{1p} + \varepsilon_1$$

$$y_2 = \beta_0 + \beta_1 x_{21} + \beta_2 x_{22} + \dots + \beta_p x_{2p} + \varepsilon_2$$

⋮

$$y_n = \beta_0 + \beta_1 x_{n1} + \beta_2 x_{n2} + \dots + \beta_p x_{np} + \varepsilon_n$$

***n* osservazioni**

***p* variabili (indipendenti)**

$$\mathbf{n > p + 1}$$

La regressione lineare multipla

$$\begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1p} \\ 1 & x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

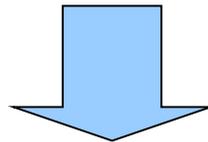
(n x 1)

(n x p)

(p x 1)

(n x 1)

y	X	β	+ ε
----------	----------	----------	------------



$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

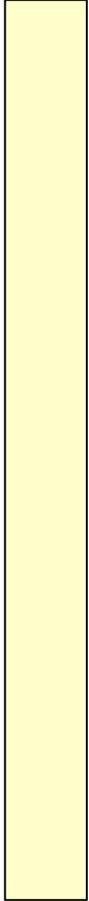
La regressione lineare multipla

$(n \times 1)$

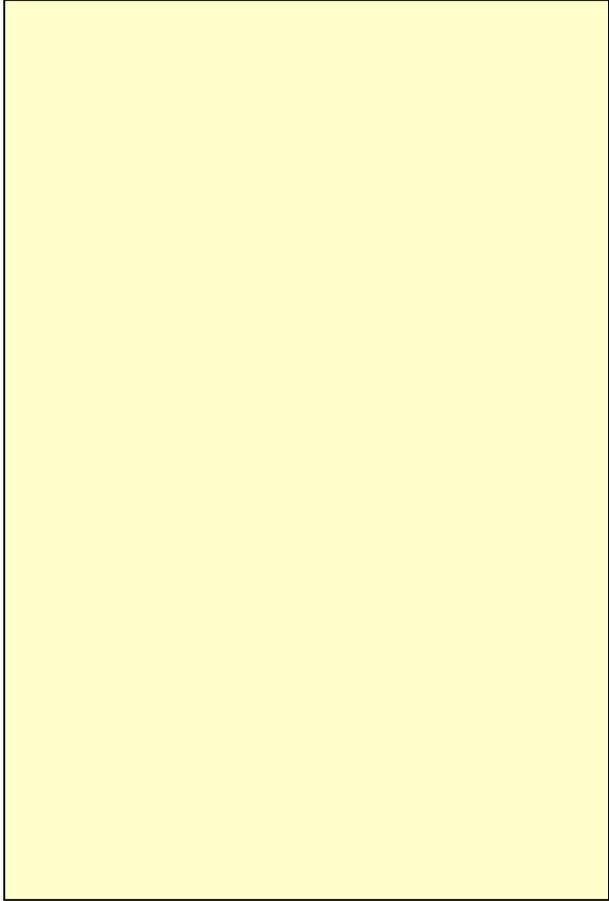
$(n \times p)$

$(p \times 1)$

$(n \times 1)$



=



*



+



y

=

X

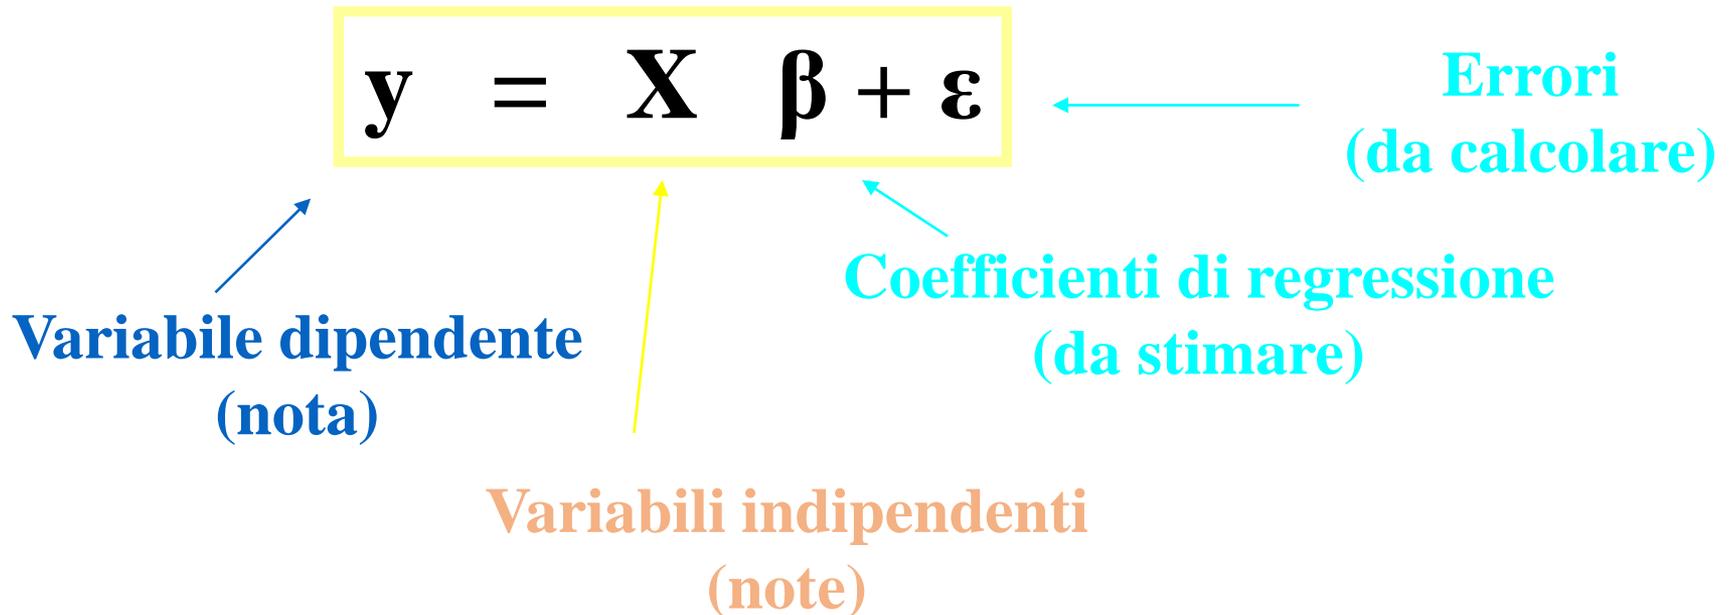
*

β

+

ε

La regressione lineare multipla



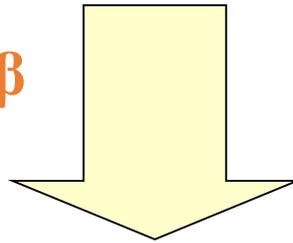
**COME STIMARE I COEFFICIENTI DI
REGRESSIONE DEL MODELLO IPOTIZZATO?**

**MINIMI QUADRATI ORDINARI
*ORDINARY LEAST SQUARES (OLS)***

La regressione lineare multipla

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \varepsilon_i$$

Ipotesi: $E(y) = X\beta$



$$E(y_i) = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip}$$

MODELLO STIMATO

\hat{y}_i 

$$\hat{E}(y_i) = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_p x_{ip}$$

La regressione lineare multipla

Le stime dei minimi quadrati di $\beta_0, \beta_1, \dots, \beta_p$ minimizzano la somma al quadrato delle deviazioni tra le osservazioni empiriche e teoriche.

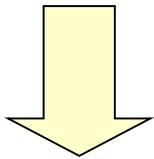
Occorre trovare quei valori di $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_p$ che minimizzano:

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \min$$

$$\begin{pmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1p} \\ 1 & x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} \begin{matrix} \\ \\ \rightarrow x_i' \\ \\ \end{matrix}$$

La regressione lineare multipla

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \min$$



$$SSE = \sum_{i=1}^n (y_i - \mathbf{x}'_i \boldsymbol{\beta})^2$$

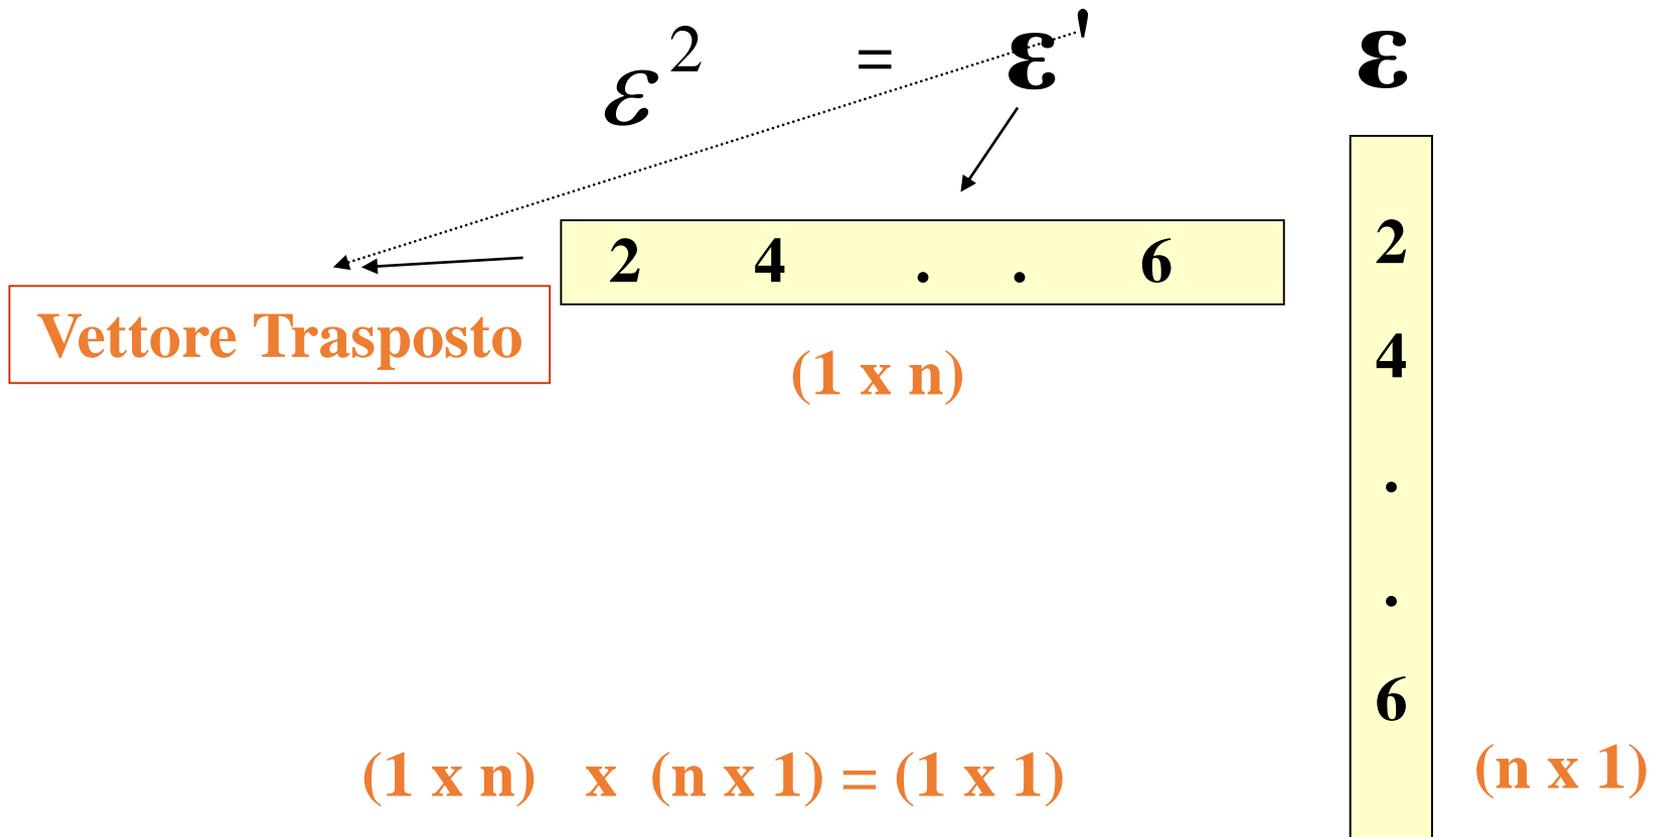
i-esimo elemento del vettore

$$\mathbf{y} - \mathbf{X}\boldsymbol{\beta}$$

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})$$

La regressione lineare multipla

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})$$



La regressione lineare multipla

$$SSE = \boldsymbol{\varepsilon}'\boldsymbol{\varepsilon} = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})$$

$$\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon} = \mathbf{y}'\mathbf{y} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta}$$

OCCORRE MINIMIZZARE!

DERIVIAMO RISPETTO A $\boldsymbol{\beta}$

$$\frac{\partial SSE(\boldsymbol{\beta})}{\partial(\boldsymbol{\beta})} = -2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = 0$$

La regressione lineare multipla

$$\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \mathbf{X}'\mathbf{y}$$

$$\boldsymbol{\beta} = ?$$

~~$$\boldsymbol{\beta} = \frac{\mathbf{X}'\mathbf{y}}{\mathbf{X}'\mathbf{X}}$$~~

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

Matrice inversa

La regressione lineare multipla

UN ESEMPIO CON EXCEL

La regressione lineare multipla

Microsoft Excel - Cartel1

File Modifica Visualizza Inserisci Formato Strumenti Dati Finestra ?

Digitare una do

Arial 10 G C S

H3

	A	B	C	D	E	F	G	H	I	J	K
1	Investimenti Reali (Y)	Costante	Trend (T)	Prodotto Nazionale Lordo (GNP)	Tasso Interesse (R)	Tasso Inflazione (P)					
2	0,161	1	1	1,058	5,16	4,4					
3	0,172	1	2	1,088	5,87	5,15					
4	0,158	1	3	1,086	5,95	5,37					
5	0,173	1	4	1,122	4,88	4,99					
6	0,195	1	5	1,186	4,5	4,16					
7	0,217	1	6	1,254	6,44	5,75					
8	0,199	1	7	1,246	7,83	8,82					
9	0,163	1	8	1,232	6,25	9,31					
10	0,195	1	9	1,298	5,5	5,21					
11	0,231	1	10	1,37	5,46	5,83					
12	0,257	1	11	1,439	7,46	7,4					
13	0,259	1	12	1,479	10,28	8,64					
14	0,225	1	13	1,474	11,77	9,31					
15	0,241	1	14	1,503	13,42	9,44					
16	0,204	1	15	1,475	11,02	5,99					
17											
18	y			X							
19											
20											
21											

MATRICE DEI DATI

Foglio1 / Foglio2 / Foglio3

Pronto NUM

La regressione lineare multipla

Ricordiamo che...

$$y = \beta_0 + \beta_1 x \quad \longrightarrow \quad \left\{ \begin{array}{l} \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \\ \hat{\beta}_1 = \frac{\text{cov}(x; y)}{\text{var}(x)} \end{array} \right.$$

$$\mathbf{y} = \mathbf{X} \boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad \longrightarrow \quad \hat{\boldsymbol{\beta}} = (\mathbf{X}' \mathbf{X})^{-1} \mathbf{X}' \mathbf{y}$$

COME FARE, USANDO UN SOFTWARE COMUNE COME EXCEL?

La regressione lineare multipla

	y	
	A	
	Investimenti Reali (Y)	Ci
1		
2	0,161	
3	0,172	
4	0,158	
5	0,173	
6	0,195	
7	0,217	
8	0,199	
9	0,163	
10	0,195	
11	0,231	
12	0,257	
13	0,259	
14	0,225	
15	0,241	
16	0,204	

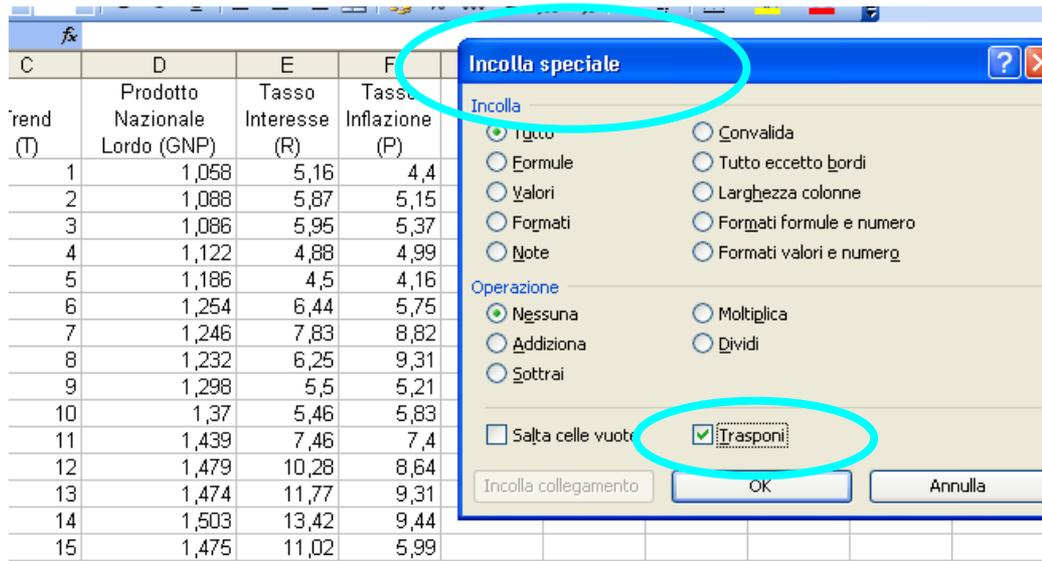
(n x 1)

	X					
	A	B	C	D	E	F
	Investimenti Reali (Y)	Costante	Trend (T)	Prodotto Nazionale Lordo (GNP)	Tasso Interesse (R)	Tasso Inflazione (P)
1						
2	0,161	1	1	1,058	5,16	4,4
3	0,172	1	2	1,088	5,87	5,15
4	0,158	1	3	1,086	5,95	5,37
5	0,173	1	4	1,122	4,88	4,99
6	0,195	1	5	1,186	4,5	4,16
7	0,217	1	6	1,254	6,44	5,75
8	0,199	1	7	1,246	7,83	8,82
9	0,163	1	8	1,232	6,25	9,31
10	0,195	1	9	1,298	5,5	5,21
11	0,231	1	10	1,37	5,46	5,83
12	0,257	1	11	1,439	7,46	7,4
13	0,259	1	12	1,479	10,28	8,64
14	0,225	1	13	1,474	11,77	9,31
15	0,241	1	14	1,503	13,42	9,44
16	0,204	1	15	1,475	11,02	5,99

(n x p)

In questo modo sarà più semplice richiamarli nelle operazioni successive.

La regressione lineare multipla



The screenshot shows an Excel spreadsheet with a matrix of data. The matrix is a 15x11 grid. The first column contains values from 0,217 to 0,204. The second column contains values from 1 to 15. The third column contains values from 6 to 15. The fourth column contains values from 1,254 to 1,475. The fifth column contains values from 6,44 to 11,02. The sixth column contains values from 5,75 to 5,99. The seventh column contains values from 8,82 to 9,44. The eighth column contains values from 9,31 to 9,44. The ninth column contains values from 5,21 to 5,99. The tenth column contains values from 5,46 to 7,4. The eleventh column contains values from 7,4 to 7,4. The matrix is highlighted in blue.

XT	A	B	C	D	E	F	G	H	I	J	K
	0,217	1	6	1,254	6,44	5,75					
	0,199	1	7	1,246	7,83	8,82					
	0,163	1	8	1,232	6,25	9,31					
	0,195	1	9	1,298	5,5	5,21					
	0,231	1	10	1,37	5,46	5,83					
	0,257	1	11	1,439	7,46	7,4					
	0,259	1	12	1,479	10,28	8,64					
	0,225	1	13	1,474	11,77	9,31					
	0,241	1	14	1,503	13,42	9,44					
	0,204	1	15	1,475	11,02	5,99					
	1	1	1	1	1	1	1	1	1	1	1
	1	2	3	4	5	6	7	8	9	10	11
	1,058	1,088	1,086	1,122	1,186	1,254	1,246	1,232	1,298	1,37	1,439
	5,16	5,87	5,95	4,88	4,5	6,44	7,83	6,25	5,5	5,46	7,46
	4,4	5,15	5,37	4,99	4,16	5,75	8,82	9,31	5,21	5,83	7,4

Matrice Trasposta
(p x n)

La regressione lineare multipla

={MATR.INVERSA(XTX)}

B	C	D	E	F
	15	120	19,31	111,79
	120	1240	164,3	1035,93
	19,31	164,3	25,218016	148,98384
	111,79	1035,93	148,98384	943,8557
	99,77	875,6	131,21625	799,0186

MATRICE INVERSA

67,4131	2,27013867	-66,77363	0,1242029	-0,071154
2,27014	0,08624091	-2,257456	-0,006399	-0,000944
-66,7736	-2,25745557	67,094376	-0,161461	-0,050552
0,1242	-0,00639861	-0,161461	0,0329547	-0,016652
-0,07115	-0,00094438	-0,050552	-0,016652	0,0402763

$$(\mathbf{X}'\mathbf{X})^{-1}$$

(p x p)

={MATR.PRODOTTO(XT;y)}

	C	D	E
115	-0,00094438	-0,050552	-0,016652

3,05
26,004
3,992563
23,52069
20,73158

$$\underbrace{\begin{matrix} \mathbf{X}' & \mathbf{y} \\ \mathbf{(p \times n)} & \mathbf{(n \times 1)} \end{matrix}}_{\mathbf{(p \times 1)}}$$

La regressione lineare multipla

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

B	C	D	E	F	G	H	I	J		
J36 (=MATR.PRODOTTO(B36:F40;H36:H40))										
	MATRICE INVERSA (X'X)⁻¹					X'y			β	
67,4131	2,27013867	-66,77363	0,1242029	-0,071154		3,05		-0,509071	Intercetta	
2,27014	0,08624091	-2,257456	-0,006399	-0,000944		26,004		-0,01658	T	
-66,7736	-2,25745557	67,094376	-0,161461	-0,050552	*	3,992563	=	0,6703834	GNP	
0,1242	-0,00639861	-0,161461	0,0329547	-0,016652		23,52069		-0,002326	R	
-0,07115	-0,00094438	-0,050552	-0,016652	0,0402763		20,73158		-9,4E-05	P	

MODELLO STIMATO

$$E(y) = -0,509 - 0,017T + 0,67GNP - 0,002R - 0,00009P$$

La regressione lineare multipla

Calcolo delle osservazioni teoriche

Formula bar: $=(\$H\$5*B2)+(\$H\$6*C2)+(\$H\$7*D2)+(\$H\$8*E2)+(\$H\$9*F2)$

Costante	Trend (T)	Prodotto Nazionale Lordo (GNP)	Tasso Interesse (R)	Tasso Inflazione (P)						Investimenti Reali (Y stimati)
1	1	1,058	5,16	4,4						0,173008
1	2	1,088	5,87	5,15						0,15488
1	3	1,086	5,95	5,37						0,164958
1	4	1,122	4,88	4,99						0,192244
1	5	1,186	4,5	4,16						0,216588
1	6	1,254	6,44	5,75						0,191123
1	7	1,246	7,83	8,82						0,168786
1	8	1,232	6,25	9,31						0,198581
1	9	1,298	5,5	5,21						0,230303
1	10	1,37	5,46	5,83						0,25518
1	11	1,439	7,46	7,4						0,258739
1	12	1,479	10,28	8,64						0,235278
1	13	1,474	11,77	9,31						0,234289
1	14	1,503	13,42	9,44						0,204844
1	15	1,475	11,02	5,99						

β		
-0,50907	Intercetta	
-0,01658	T	
0,670383	GNP	
-0,00233	R	
-9,4E-05	P	

Calcolo dei residui

Formula bar: $=C21-D21$

Investimenti Reali (Y)	Investimenti Reali (Y stimati)	Residui
0,161	0,171199	-0,0102
0,172	0,173008	-0,00101
0,158	0,15488	0,00312
0,173	0,164958	0,008042
0,195	0,192244	0,002756
0,217	0,216588	0,000412
0,199	0,191123	0,007877
0,163	0,168786	-0,00579
0,195	0,198581	-0,00358
0,231	0,230303	0,000697
0,257	0,25518	0,00182
0,259	0,258739	0,000261
0,225	0,235278	-0,01028
0,241	0,234289	0,006711
0,204	0,204844	-0,00084

La regressione lineare multipla

LA BONTÀ DI ADATTAMENTO DEL MODELLO

Il modello stimato si adatterà tanto più alle osservazioni y_i quanto più modesta sarà la variabilità dell'errore rispetto alla variabilità totale

$$\sum_i (y_i - \bar{y})^2 = \sum_i (\hat{y}_i - \bar{y})^2 + \sum_i (y_i - \hat{y}_i)^2$$

$$\text{SST} = \text{SSR} + \text{SSE}$$

$$R^2 = \frac{\text{devianza di regressione}}{\text{devianza totale}} \quad \Rightarrow \quad R^2 = \frac{\hat{\beta}' X' y - n\bar{y}^2}{y' y - n\bar{y}^2}$$

$$R^2 \text{ corretto: } R_c^2 = 1 - \frac{n-1}{n-p-1} (1 - R^2)$$

Osservazioni
(n=15)

Variabili
(p=4)

La regressione lineare multipla

L'ANALISI DELLA VARIANZA

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_q = 0$$

Non è inclusa l'intercetta,
perché si ipotizza che essa
sia diversa da zero.

$$F = \frac{\frac{SSR}{p}}{\frac{SSE}{n-p-1}} \sim F_{p;n-p-1}$$

$$F > F_{\alpha;p;n-p-1}$$

Rigetto H_0

$$F < F_{\alpha;p;n-p-1}$$

Accetto H_0

RICORDATE

La regressione lineare multipla

L'ANALISI DELLA VARIANZA

	Fonte	Gradi di Libertà	Media dei quadrati
Regressione (SSR)	$\hat{\beta}'X'y - n\bar{y}^2$	p	$\frac{\hat{\beta}'X'y - n\bar{y}^2}{p}$
Residua (SSE)	$e'e$	$n - p - 1$	$\frac{e'e}{n - p - 1}$
Totale (SST)	$y'y - n\bar{y}^2$	$n - 1$	$\frac{y'y - n\bar{y}^2}{n - 1}$

$$\text{SST} = \text{SSR} + \text{SSE}$$

La regressione lineare multipla

	Fonte di variabilità	Gradi di Libertà	Media dei quadrati
Regressione	0,015902522	4	0,003976
Residua	0,0004508	10	0,00004508
Totale	0,016353333	14	0,0011681

La regressione lineare multipla

$$F = \frac{\frac{SSR}{p}}{\frac{SSE}{n-p-1}} \sim F_{p;n-p-1}$$

$$\begin{aligned} p &= 4 \\ n - p - 1 &= 10 \\ \alpha &= 0,05 \quad (5\%) \end{aligned}$$

$$F = \frac{\frac{SSR}{p}}{\frac{SSE}{n-p-1}} = \frac{\frac{0,015902522}{4}}{\frac{0,0004508}{10}} = 88,190$$

$$F_{\alpha;p;n-p-1} = 3,48$$

$$F > F_{\alpha;p;n-p-1}$$

Rigetto H_0

La regressione lineare multipla

SIGNIFICATIVITA' DEI SINGOLI PARAMETRI

Si usa, comunemente, il test t.

$$H_0 : \beta_i = 0$$

$$t = \frac{\hat{\beta}_i}{s_{\beta_i}}$$

Stima (nel campione) di β_p

Standard error di β_p

?

$$t > t_{\alpha/2; n-p}$$

Rigetto H_0

$$t < t_{\alpha/2; n-p}$$

Accetto H_0

La regressione lineare multipla

$$\text{Var}(\hat{\boldsymbol{\beta}}) = E(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})' =$$

$$= E \left[(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}'\mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \right] =$$

$$= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' (\sigma^2 \mathbf{I}) \mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} =$$

$$= \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$$

NON E' NOTA

s^2 è una stima (corretta) di σ^2

i
p
o
t
e
s
i

$$\begin{cases} E(\boldsymbol{\varepsilon}) = 0 \\ E(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}') = \sigma^2 \mathbf{I} \end{cases}$$

La regressione lineare multipla

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

$$\text{Est. Var}(\hat{\boldsymbol{\beta}}) = s^2 (\mathbf{X}'\mathbf{X})^{-1}$$

$$s^2 = \frac{\mathbf{e}'\mathbf{e}}{n - p - 1}$$

La radice quadrata del *p*-esimo elemento diagonale della matrice, è l'errore standard del parametro stimato.

La regressione lineare multipla

$$X'X = \begin{vmatrix} 15 & 120 & 19,31 & 111,79 & 99,77 \\ 120 & 1240 & 164,3 & 1035,93 & 875,6 \\ 19,31 & 164,3 & 25,218 & 148,984 & 131,216 \\ 111,79 & 1035,93 & 148,984 & 943,856 & 799,019 \\ 99,77 & 875,6 & 131,216 & 799,019 & 716,669 \end{vmatrix}$$

$$e'e = 0,00045 \quad s^2 = \frac{e'e}{n-p-1}$$

$$s^2 = 4,5E-05$$

$(X'X)^{-1}$

$$(X'X)^{-1} = \begin{vmatrix} 67,4131 & 2,27014 & -66,7736 & 0,1242 & -0,07115 \\ 2,27014 & 0,08624 & -2,25746 & -0,0064 & -0,00094 \\ -66,7736 & -2,25746 & 67,0944 & -0,16146 & -0,05055 \\ 0,1242 & -0,0064 & -0,16146 & 0,03295 & -0,01665 \\ -0,07115 & -0,00094 & -0,05055 & -0,01665 & 0,04028 \end{vmatrix}$$

$s^2(X'X)^{-1}$

$$s^2(X'X)^{-1} = \begin{vmatrix} 0,00304 & 0,0001 & -0,00301 & 5,6E-06 & -3,2077E-06 \\ 0,0001 & 4E-06 & -0,0001 & -3E-07 & -4,2574E-08 \\ -0,00301 & -0,0001 & 0,00302 & -7E-06 & -2,2789E-06 \\ 5,6E-06 & -3E-07 & -7,3E-06 & 1,5E-06 & -7,5071E-07 \\ -3,2E-06 & -4E-08 & -2,3E-06 & -8E-07 & 1,8157E-06 \end{vmatrix}$$

ERRORI STANDARD

s_{β_0}	0,05513		
s_{β_1}		0,00197	
\vdots			
s_{β_5}			0,00135

0,055
0,00122

Radice quadrata



La regressione lineare multipla

$$H_0 : \beta_i = 0$$

$$t = \frac{\hat{\beta}_i}{S_{\beta_i}}$$

	ERRORI STANDARD	$\hat{\beta}$	t
Intercetta	0,05513	-0,50907	-9,23439
T	0,00197176	-0,01658	-8,40893
GNP	0,05499721	0,67038	12,1894
R	0,00121887	-0,00233	-1,90827
P	0,00134748	-9,4E-05	-0,06977

Si confrontano con i valori tabulati della t di Student, con significatività $\alpha/2$ (α) e gradi di libertà pari a $(n - p)$.

La regressione lineare multipla

	ERRORI STANDARD	$\hat{\beta}$	t
Intercetta	0,05513	-0,50907	-9,23439
T	0,00197176	-0,01658	-8,40893
GNP	0,05499721	0,67038	12,1894
R	0,00121887	-0,00233	-1,90827 *
P	0,00134748	-9,4E-05	-0,06977 *

$$t_{\alpha/2;11} = 2,201$$

**Significativamente
pari a zero.**

$$t > t_{\alpha/2;n-p}$$

Rigetto H_0

$$t < t_{\alpha/2;n-p}$$

Accetto H_0

RICORDATE

La regressione lineare multipla

STIMA PER INTERVALLO

$$\text{Prob}\left(\hat{\beta}_i - t_{\alpha/2} s_{\beta_i} \leq \beta_i \leq \hat{\beta}_i + t_{\alpha/2} s_{\beta_i}\right) = 1 - \alpha$$

$\alpha \rightarrow 5\%$

$$t_{\alpha/2;11} = 2,201$$

	Errore standard	$\hat{\beta}$	Limite inferiore	Limite superiore
Intercetta	0,05513	-0,509071	-0,632	-0,386
T	0,001971761	-0,01658	-0,021	-0,012
GNP	0,054997215	0,670383	0,548	0,793
R	0,001218868	-0,002326	-0,005	0,000
P	0,00134748	-9,4E-05	-0,003	0,003

La regressione lineare multipla

MULTICOLLINEARITÀ

$$VIF_i = \frac{1}{1 - R_i^2} \quad VIF_i \geq 10$$

Collinearità

= correlazione(a1:a15; b1:b15)

Trend (T)	Prodotto Nazionale Lordo (GNP)	Tasso Interesse (R)	Tasso Inflazione (P)		
1	1,058	5,16	4,4		
2	1,088	5,87	5,15		
3	1,086	5,95	5,37		
4	1,122	4,88	4,99		
5	1,186	4,5	4,16		
6	1,254	6,44	5,75		
7	1,246	7,83	8,82		
8	1,232	6,25	9,31		
9	1,298	5,5	5,21		
10	1,37	5,46	5,83		
11	1,439	7,46	7,4		
12	1,479	10,28	8,64		
13	1,474	11,77	9,31		
14	1,503	13,42	9,44		
15	1,475	11,02	5,99		

Correlazioni				
T e GNP	0,978627			
T e R	0,804262			
T e P	0,635305			
GNP e R	0,803932			
GNP e P	0,636165			
R e P	0,723613			

MATRICE DI CORRELAZIONE				
	T	GNP	R	P
T	1	0,978627	0,804262	0,635305
GNP	0,978627	1	0,803932	0,636165
R	0,804262	0,803932	1	0,723613
P	0,635305	0,636165	0,723613	1

MATRICE DI CORRELAZIONE				
	T	GNP	R	P
T	1	0,978627	0,804262	0,635305
GNP	0,978627	1	0,803932	0,636165
R	0,804262	0,803932	1	0,723613
P	0,635305	0,636165	0,723613	1

INVERSA MATRICE DI CORRELAZIONE				
24,14745	-22,6524	-1,12663	-0,11511	
-22,6524	24,12776	-1,01883	-0,22083	
-1,12663	-1,01883	3,648818	-1,27643	
-0,11511	-0,22083	-1,27643	2,137261	

VIF

La regressione lineare multipla

VERIFICA DELLE IPOTESI SUI RESIDUI

Occorre verificare le note ipotesi sui residui:

- **assenza di correlazione (autocorrelazione)**
- **omoshedasticità (varianza costante)**
- **distribuzione normale**

La regressione lineare multipla

PRESENZA DI AUTOCORRELAZIONE

Test di Durbin – Watson (DW)

$$H_0 : \rho = 0$$

$$DW = \frac{\sum_{i=2}^n (e_i - e_{i-1})^2}{\sum_{i=1}^n (e_i)^2}$$

= 2 assenza di autocorrelazione
 < 2 autocorrelazione positiva
 > 2 autocorrelazione negativa

i	Res(i)	Res(i)^2	Res (i-1)	Res(i) - Res(i-1)	(Res(i) - Res(i-1))^2
1	-0,0102	0,000104021			
2	-0,00101	1,01656E-06	-0,0102	0,009190809	8,4471E-05
3	0,00312	9,73236E-06	0,00101	0,004127918	1,70397E-05
4	0,00804	6,46705E-05	0,00312	0,004922123	2,42273E-05
5	0,00276	7,59426E-06	0,008042	-0,005286027	2,79421E-05
6	0,00041	1,69635E-07	0,002756	-0,002343901	5,49387E-06
7	0,00788	6,20469E-05	0,000412	0,007465115	5,57279E-05
8	-0,00579	3,34796E-05	0,007877	-0,013663139	0,000186681
9	-0,00358	1,28233E-05	-0,00579	0,002205197	4,8629E-06
10	0,0007	4,85917E-07	-0,00358	0,004278036	1,83016E-05
11	0,00182	3,3141E-06	0,000697	0,001123391	1,26201E-06
12	0,00026	6,8234E-08	0,00182	-0,001559252	2,43127E-06
13	-0,01028	0,000105634	0,000261	-0,010539068	0,000111072
14	0,00671	4,50432E-05	-0,01028	0,016989278	0,000288636
15	-0,00084	7,12349E-07	0,006711	-0,007555434	5,70846E-05
SOMME		0,000450812			0,000885233
DW =		1,96364226			

La regressione lineare multipla

OMOSCHEDASTICITÀ

Test di White

È basato sul valore del coefficiente di determinazione R^2 relativo alla regressione dei quadrati dei residui su una costante, sui quadrati dei regressori e sui loro prodotti incrociati.

$$e_i^2 = \beta_0 + \beta_1 T^2 + \beta_2 GNP^2 + \beta_3 R^2 + \beta_4 P^2 + \beta_5 (T)(GNP) + \dots + \beta_{10} (R)(P)$$

$$H_0 : \sigma_{\varepsilon_i}^2 = \sigma_{\varepsilon}^2 \quad \forall i$$

$$nR^2 \sim \chi_{\alpha; p-1}^2$$

$$R^2 = 0,765 \quad nR^2 = 15 * 0,765 = 11,475 \quad \chi_{0,05;9}^2 = 16,919$$

Accetto H_0

La regressione lineare multipla

DISTRIBUZIONE NORMALE

Test di Jarque – Bera (JB)

La statistica test di JB misura la differenza dell'asimmetria e della curtosi della serie (dei residui) da quella della distribuzione normale.

$$H_0 : \varepsilon \sim N$$

Asimmetria

$$S = \frac{1}{n} \sum_{i=1}^n \left(\frac{e_i - \bar{e}}{\sigma} \right)^3$$

Curtosi

$$K = \frac{1}{n} \sum_{i=1}^n \left(\frac{e_i - \bar{e}}{\sigma} \right)^4$$

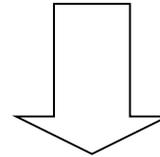
$$JB = \frac{N-p}{6} \left(S^2 + \frac{(K-3)^2}{4} \right)$$

$$JB \sim \chi_{\alpha;2}^2$$

La regressione lineare multipla

i	Res(i)
1	-0,0102
2	-0,00101
3	0,00312
4	0,00804
5	0,00276
6	0,00041
7	0,00788
8	-0,00579
9	-0,00358
10	0,0007
11	0,00182
12	0,00026
13	-0,01028
14	0,00671
15	-0,00084
Asimmetria	-0,45997
Curtosi	-0,22006

$$JB = \frac{N-p}{6} \left(S^2 + \frac{1}{4} K^2 \right) \quad JB \sim \chi_{\alpha;2}^2$$



$$JB = \frac{15-4}{6} \left((-0,46)^2 + \frac{1}{4} (-0,22)^2 \right) = 0,41$$

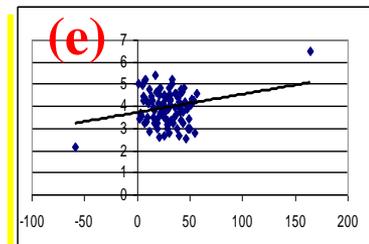
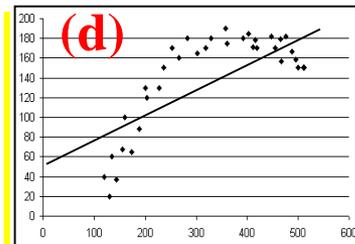
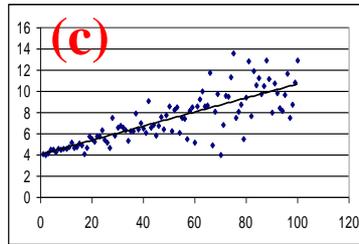
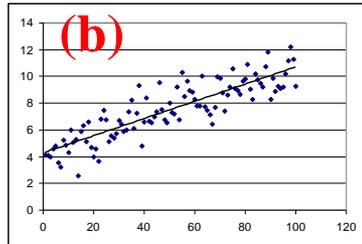
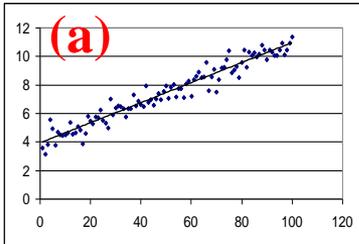
=asimmetria(a1:a15)

=curtosi(a1:a15)

$$\chi_{0,05;2}^2 = 5,991$$

Accetto H_0

La regressione lineare semplice



F 1524,046 0,000
a 3,920 0,000
b 0,070 0,000
R² 0,940
DW 2,002

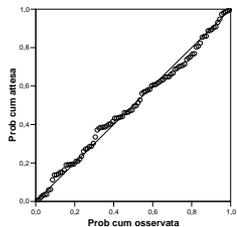
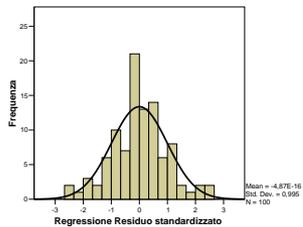
F 298,305 0,000
a 4,247 0,000
b 0,064 0,000
R² 0,753
DW 1,989

F 173,175 0,000
a 4,025 0,000
b 0,066 0,000
R² 0,639
DW 1,041

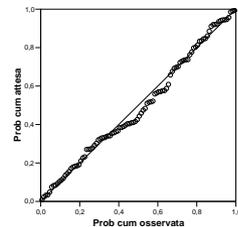
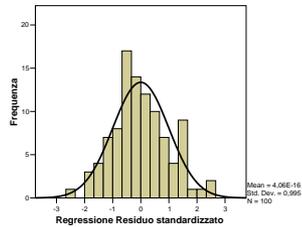
F 45,81 0,000
a 48,058 0,000
b 0,283 0,000
R² 0,581
DW 0,338

F 5,797 0,018
a 3,697 0,000
b 0,008 0,038
R² 0,057
DW 2,001

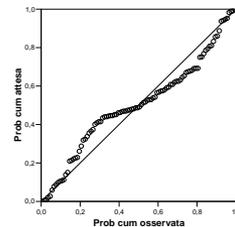
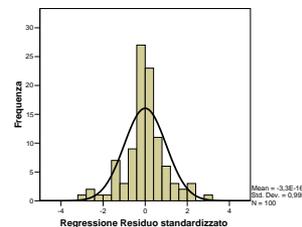
Istogramma



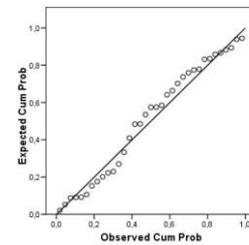
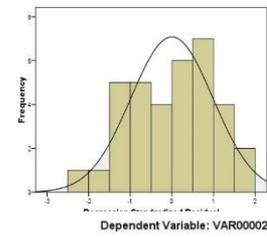
Istogramma



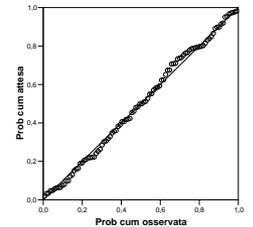
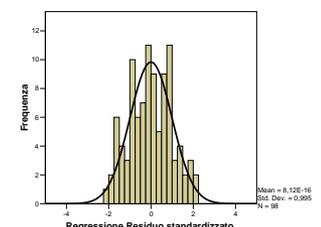
Istogramma



Istogramma



Istogramma

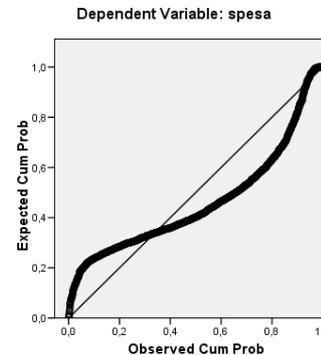
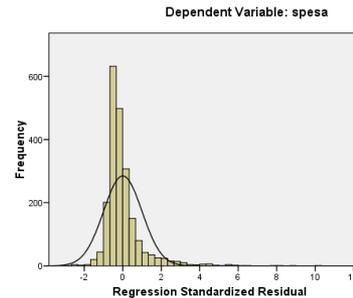
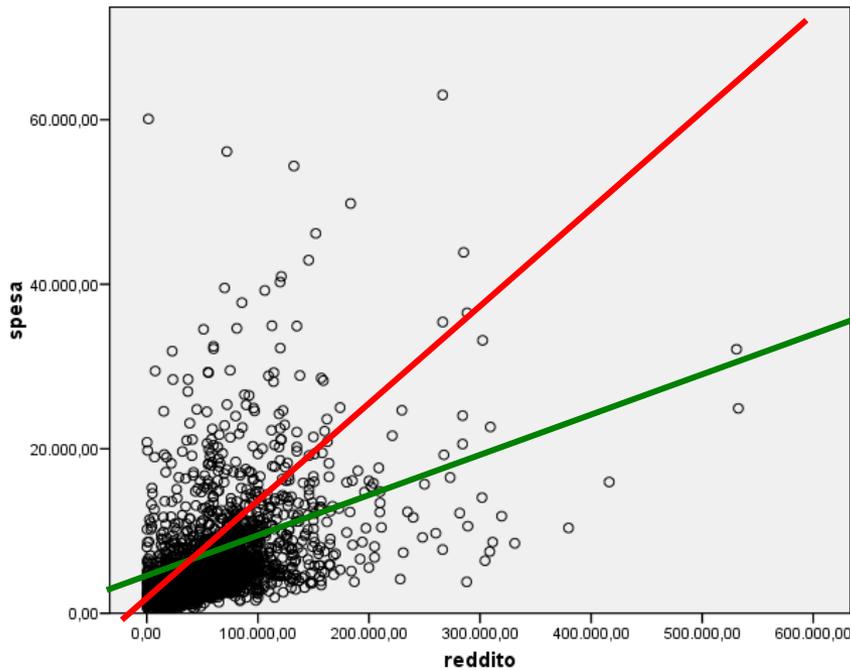


La regressione lineare: un caso di studio

$$\text{Consumi} = a + b * \text{Reddito}$$

PROPENSIONE MARGINALE AL CONSUMO –
COEFFICIENTE ANGOLARE DELLA RETTA

CONSUMO DI SOPRAVVIVENZA PRESENTE
ANCHE SE REDDITO = 0 – INTERCETTA
DELLA RETTA



$R^2 = 0,207$

$F = 558,100$ $0,000$

$a = 3065$ $0,000$

$b = 0,057$ $0,000$

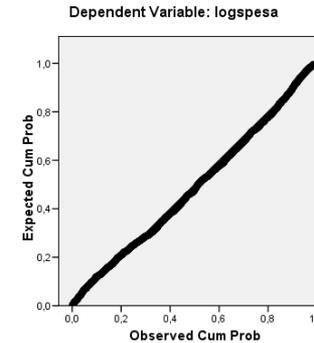
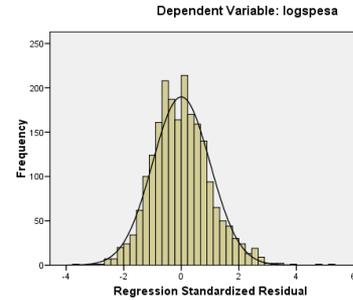
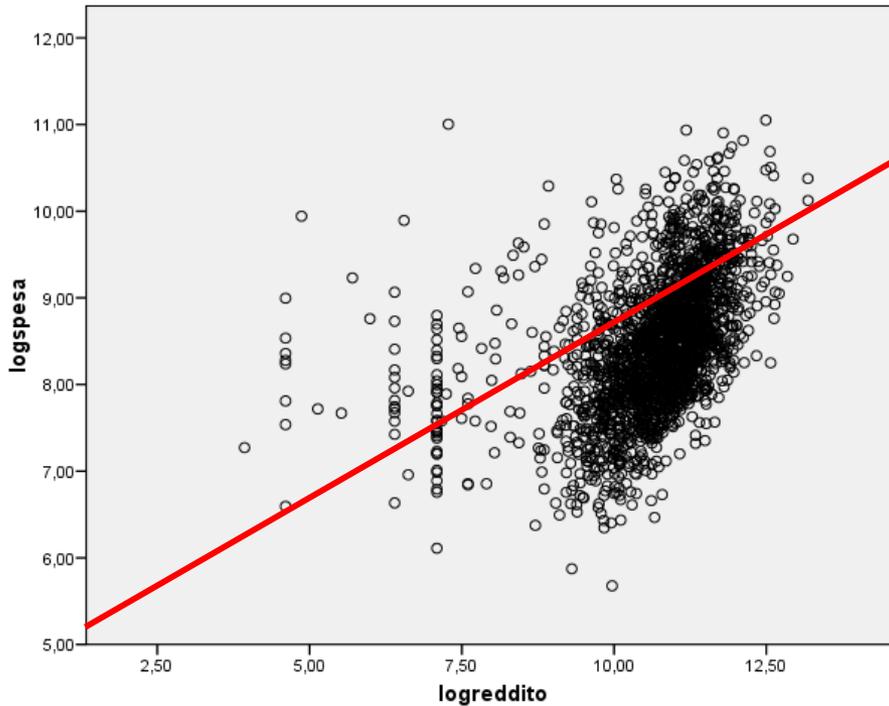
$DW = 2,012$

La regressione lineare: un caso di studio

$$\text{Log(Consumi)} = a + b \cdot \text{log(Reddito)}$$

ELASTICITA' DEL CONSUMO RISPETTO AL REDDITO – COEFFICIENTE ANGOLARE DELLA RETTA

LOG DEL CONSUMO DI SOPRAVVIVENZA PRESENTE ANCHE SE LOG(REDDITO) = 0 – INTERCETTA DELLA RETTA



$R^2 = 0,196$

$F = 522,445$ $0,000$

$a = 5,113$ $0,000$

$b = 0,316$ $0,000$

$DW = 1,931$

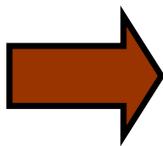
La regressione lineare multipla: cosa cambia?

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_px_p$$

$$R_{Adj}^2 = 1 - \frac{n-1}{n-p-1} (1 - R^2)$$

$$VIF_i = \frac{1}{1 - R_i^2}$$

**PRINCIPIO DI
PARSIMONIA: usare
il minor numero
possibile di variabili
indipendenti**



**IMPATTO CHE
OGNI VARIABILE
HA SUL VALORE
DI F**

FORWARD
BACKWARD
STEPWISE

La regressione lineare multipla: un esercizio

$$\text{Log}(C) = b_0 + b_1\text{Log}(R) + b_2qc + b_3f + b_4ef + b_5em + b_6sf + b_7sm$$

Dove:

C *consumi*

R *reddito*

qc *quota dei consumi destinato ai prodotti alimentari*

f *numero dei figli*

ef *età della moglie*

em *età del marito*

sf *anni di studio della moglie*

sm *anni di studio del marito*

1° metodo - Enter o blocco - usare tutte le variabili

2° metodo - Forward

3° metodo - Stepwise

La regressione lineare multipla: metodo enter

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,598 ^a	,357	,355	*****	1,954

a. Predictors: (Constant), quotacibo, figli, annistfem, lreddito, etam, annistmas, etaf

b. Dependent Variable: Ispesa

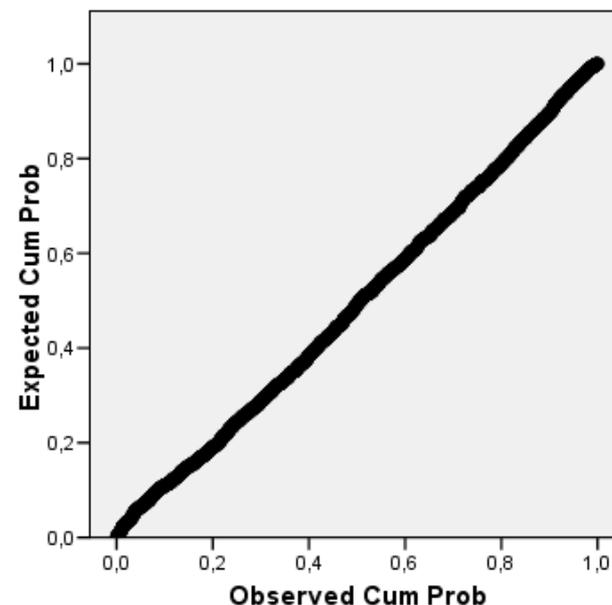
ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	469,671	7	67,096	169,223	,000 ^a
	Residual	845,720	2133	,396		
	Total	1315,391	2140			

a. Predictors: (Constant), quotacibo, figli, annistfem, lreddito, etam, annistmas, etaf

b. Dependent Variable: Ispesa

Dependent Variable: Ispesa



Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	6,526	,171		38,147	,000		
	lreddito	,186	,014	,261	13,437	,000	,802	1,248
	figli	,055	,013	,086	4,244	,000	,740	1,351
	etaf	,002	,003	,042	,770	,441	,099	10,084
	etam	-,003	,003	-,061	-1,117	,264	,100	10,012
	annistfem	,012	,004	,063	3,097	,002	,734	1,363
	annistmas	,028	,004	,147	7,134	,000	,709	1,411
	quotacibo	-2,922	,157	-,343	-18,555	,000	,881	1,136

a. Dependent Variable: Ispesa

La regressione lineare multipla: metodo forward

Variables Entered/Removed^a

Model	Variables Entered	Variables Removed	Method
1	quotacibo		Forward (Criterion: Probabilit y-of F-to-enter <= ,050)
2	reddito		Forward (Criterion: Probabilit y-of F-to-enter <= ,050)
3	annistmas		Forward (Criterion: Probabilit y-of F-to-enter <= ,050)
4	figli		Forward (Criterion: Probabilit y-of F-to-enter <= ,050)
5	annistfem		Forward (Criterion: Probabilit y-of F-to-enter <= ,050)

a. Dependent Variable: Ispesa

SSR

$$F = \frac{p}{SSE} \frac{1}{n - p - 1}$$

ANOVA

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	288,764	1	288,764	601,647	,000 ^a
	Residual	1026,627	2139	,480		
	Total	1315,391	2140			
2	Regression	417,681	2	208,840	497,378	,000 ^b
	Residual	897,710	2138	,420		
	Total	1315,391	2140			
3	Regression	452,664	3	150,888	373,754	,000 ^c
	Residual	862,727	2137	,404		
	Total	1315,391	2140			
4	Regression	464,908	4	116,227	291,906	,000 ^d
	Residual	850,483	2136	,398		
	Total	1315,391	2140			
5	Regression	468,973	5	93,795	236,587	,000 ^e
	Residual	846,418	2135	,396		
	Total	1315,391	2140			

a. Predictors: (Constant), quotacibo

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	9,137	,031		294,585	,000
	quotacibo	-3,988	,163	-,469	-24,528	,000
2	(Constant)	6,496	,153		42,319	,000
	quotacibo	-3,118	,160	-,366	-19,488	,000
	reddito	,235	,013	,329	17,522	,000
3	(Constant)	6,447	,151		42,811	,000
	quotacibo	-2,915	,158	-,342	-18,405	,000
	reddito	,201	,014	,282	14,781	,000
4	(Constant)	6,480	,150		43,293	,000
	quotacibo	-2,956	,157	-,347	-18,773	,000
	reddito	,192	,014	,270	14,131	,000
5	(Constant)	6,444	,150		43,029	,000
	quotacibo	-2,929	,157	-,344	-18,611	,000
	reddito	,188	,014	,264	13,772	,000
5	annistmas	,028	,004	,148	7,162	,000
	figli	,060	,011	,094	5,365	,000
	annistfem	,013	,004	,065	3,202	,001

a. Dependent Variable: Ispesa

Model Summary^a

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,469 ^a	,220	,219	*****	
2	,564 ^b	,318	,317	*****	
3	,587 ^c	,344	,343	*****	
4	,595 ^d	,353	,352	*****	
5	,597 ^e	,357	,355	*****	1,953

a. Predictors: (Constant), quotacibo

b. Predictors: (Constant), quotacibo, reddito

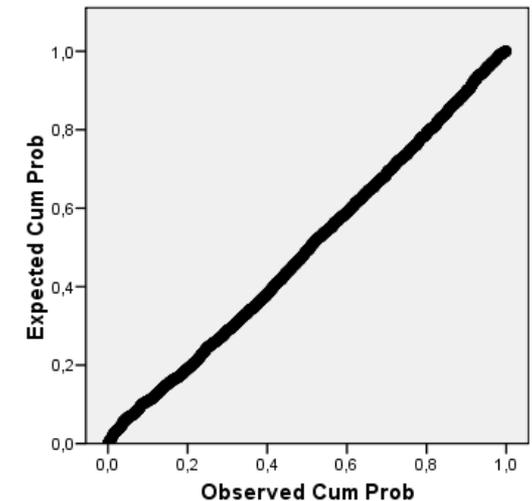
c. Predictors: (Constant), quotacibo, reddito, annistmas

d. Predictors: (Constant), quotacibo, reddito, annistmas, figli

e. Predictors: (Constant), quotacibo, reddito, annistmas, figli, annistfem

f. Dependent Variable: Ispesa

Dependent Variable: Ispesa



La regressione lineare multipla: metodo stepwise

Variables Entered/Removed^b

Model	Variables Entered	Variables Removed	Method
1	quotacibo, figli, annistfem, Ireddito, etam, annistmas, etaf ^a		Enter
2		etaf	Backward (criterion: Probability of F-to-remove >= ,100).
3		etam	Backward (criterion: Probability of F-to-remove >= ,100).

a. All requested variables entered.

b. Dependent Variable: Ispesa

Model Summary^d

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,598 ^a	,357	,355	*****	
2	,597 ^b	,357	,355	*****	
3	,597 ^c	,357	,355	*****	1,953

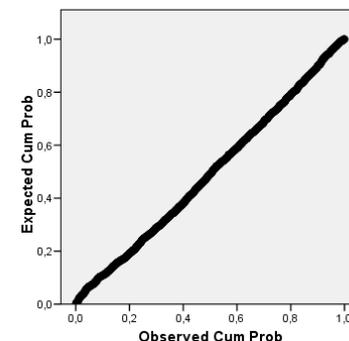
a. Predictors: (Constant), quotacibo, figli, annistfem, Ireddito, etam, annistmas, etaf

b. Predictors: (Constant), quotacibo, figli, annistfem, Ireddito, etam, annistmas

c. Predictors: (Constant), quotacibo, figli, annistfem, Ireddito, annistmas

d. Dependent Variable: Ispesa

Dependent Variable: Ispesa



Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	6,526	,171		38,147	,000
	Ireddito	,186	,014	,261	13,437	,000
	figli	,055	,013	,086	4,244	,000
	etaf	,002	,003	,042	,770	,441
	etam	-,003	,003	-,061	-1,117	,264
	annistfem	,012	,004	,063	3,097	,002
	annistmas	,028	,004	,147	7,134	,000
	quotacibo	-2,922	,157	-,343	-18,555	,000
2	(Constant)	6,533	,171		38,242	,000
	Ireddito	,186	,014	,261	13,443	,000
	figli	,053	,013	,084	4,179	,000
	etam	-,001	,001	-,022	-1,080	,280
	annistfem	,012	,004	,063	3,085	,002
	annistmas	,028	,004	,148	7,171	,000
3	(Constant)	6,444	,150		43,029	,000
	Ireddito	,188	,014	,264	13,772	,000
	figli	,060	,011	,094	5,365	,000
	annistfem	,013	,004	,065	3,202	,001
	annistmas	,028	,004	,148	7,162	,000
quotacibo	-2,929	,157	-,344	-18,611	,000	

a. Dependent Variable: Ispesa

ANOVA^d

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	469,671	7	67,096	169,223	,000 ^a
	Residual	845,720	2133	,396		
	Total	1315,391	2140			
2	Regression	469,436	6	78,239	197,366	,000 ^b
	Residual	845,955	2134	,396		
	Total	1315,391	2140			
3	Regression	468,973	5	93,795	236,587	,000 ^c
	Residual	846,418	2135	,396		
	Total	1315,391	2140			

a. Predictors: (Constant), quotacibo, figli, annistfem, Ireddito, etam, annistmas, etaf

b. Predictors: (Constant), quotacibo, figli, annistfem, Ireddito, etam, annistmas

c. Predictors: (Constant), quotacibo, figli, annistfem, Ireddito, annistmas