

Regressione lineare

Nello studio della relazione tra variabili cardinali

- Significatività
- Forza
- Forma (ricondata ad una relazione analiticamente nota)




MODELLO STATISTICO

La legge fondamentale della *psicofisica*

R (stimolo)	S (sensazione)
1	0,0
1	0,0
2	0,6
3	1,0
4	1,2
5	1,4
6	1,6
7	1,7
8	1,8
9	1,9
10	2,0
11	2,1
12	2,2
13	2,2
14	2,3
15	2,4
16	2,4
17	2,5
18	2,5
19	2,6
20	2,6

Studio della relazione



$$S=2 \log R$$

Definizione di una relazione analitica

I modelli lineari esprimono una variabile dipendente (Y) come funzione lineare di almeno una variabile indipendente (X) ed una componente di errore (errore stocastico ε)


$$Y_i = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon_i$$

$$Y_i = \alpha + \sum_{k=1}^K \beta_{ki} X_{ki} + \varepsilon_i$$

Regressione lineare

Aprile, 2005

Data una distribuzione empirica di due variabili (X,Y), rappresentata con un grafico di dispersione, la retta di regressione è quella che interpola al meglio la nube di punti.




Regressione lineare

Aprile, 2005

$$E(Y_i) = \alpha + \beta_1 X_{1i}$$

Il valore atteso di Y è funzione di X.




Regressione lineare

Aprile, 2005

La differenza $\varepsilon_i = Y_i - E(Y_i)$ è l'errore stocastico

La retta che interpola al meglio la nuvola di punti è quella che minimizza la somma del quadrato degli errori

Minimi Quadrati Ordinari



Regressione lineare

Aprile, 2005

Assunti

a) $E(\varepsilon_i) = 0$

b) $COV(X, \varepsilon_i) = 0$

c) $COV(\varepsilon_j, \varepsilon_i) = 0$

d) $VAR(\varepsilon_j) = VAR(\varepsilon_i)$ Omoschedasticità

f) Distribuzione normale degli errori

$$\hat{Y}_i = a + b X_i + e_i$$


Per stimare i parametri alfa e beta si utilizza il metodo dei minimi quadrati ordinari.

$$a = \bar{Y} - b\bar{X}$$

$$b = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} = \frac{COV_{x,y}}{VAR_x}$$

Esempio

Ident	Giorni di studio	Votazione
1	25	27
2	38	28
3	41	29
4	27	25
5	56	24
6	32	30
7	15	18
8	10	12
9	26	25
10	18	20



Regressione lineare

Aprile, 2005


Esempio

Ident	Giorni di studio	Votazione	x-xmedio	y-ymedio	(x-xmedio) ²	(x-xmedio) * (y-ymedio)
1	25	27	-3,8	3,2	14,44	-12,16
2	38	28	9,2	4,2	84,64	38,64
3	41	29	12,2	5,2	148,84	63,44
4	27	25	-1,8	1,2	3,24	-2,16
5	56	24	27,2	0,2	739,84	5,44
6	32	30	3,2	6,2	10,24	19,84
7	15	18	-13,8	-5,8	190,44	80,04
8	10	12	-18,8	-11,8	353,44	221,84
9	26	25	-2,8	1,2	7,84	-3,36
10	18	20	-10,8	-3,8	116,64	41,04
media	28,8	23,8		sommatoria	1669,6	452,6
				b	0,27	
				a	15,99	

Regressione lineare

Aprile, 2005

Esempio



Regressione lineare

Aprile, 2005

Bontà adattamento della retta

Attraverso il coefficiente di determinazione R^2 otteniamo un valore interpretabile come varianza della variabile Y riprodotta dalla variabile X


$$R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} = \frac{b^2 \text{VAR}(X)}{\text{VAR}(Y)}$$

Regressione lineare

Aprile, 2005

Applicando la funzione definita possiamo ricostruire le votazioni dei soggetti (anche per prevedere il voto in base alle ore di studio)

Ident	Giorni di studio	Votazione	Votazione hat
1	25	27	22,8
2	38	28	26,3
3	41	29	27,1
4	27	25	23,3
5	56	24	31,2
6	32	30	24,7
7	15	18	20,1
8	10	12	18,7
9	26	25	23,0
10	18	20	20,9
11	15,9	mancante	20,3



Analisi della Varianza - ANOVA

Aprile, 2005

esercitazione

ident	ore lettura settimana	genere lettura	ORE TV	TITOLO DI STUDIO
2	20	1	6	2
5	8	1	14	3
6	5	1	22	2
8	3	1	36	2
10	13	1	11	3
15	1	1	41	3
20	6	1	23	3
1	15	2	7	1
9	2	2	53	1
11	9	2	15	1
13	3	2	38	3
14	1	2	29	1
16	5	2	25	1
17	2	2	17	1
3	5	3	21	1
4	4	3	26	3
7	9	3	13	2
12	15	3	11	2
18	2	3	56	2
19	11	3	15	2
21	5	3	27	3
		1=giallo		1=obbligo
		2=classico		2=m. sup
		3=fant.		3=laurea