

# Psicometria 2

## 1. regressione lineare (iv)

**Michele Grassi**

Dipartimento di Psicologia, Università di Trieste

Modulo 2, 4 C.F.U.

Marzo – Aprile 2012

## Regressione lineare bivariata

1. Dati questi vettori  $x$  e  $y$ , utilizzando solo l'algebra lineare calcola i parametri  $a$  e  $b$  della retta di regressione:

$$x = \begin{bmatrix} 2 \\ 3 \\ 1 \\ 4 \\ 5 \\ 8 \end{bmatrix}; \quad y = \begin{bmatrix} 3 \\ 2 \\ 2 \\ 7 \\ 6 \\ 7 \end{bmatrix}.$$

2. Dai dati precedenti, calcola  $SQ_{TOT}$ ,  $SQ_{REG}$  e  $SQ_{ERR}$ .
3. Calcola inoltre l'indice  $R^2$

136

## Regressione - soluzione

1. Dati i vettori  $x$  e  $y$ , utilizzando solo l'algebra lineare calcola i parametri  $a$  e  $b$  della retta di regressione:

Occorre applicare questa formula: 
$$\begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{bmatrix}^{-1} \begin{bmatrix} \sum y_i \\ \sum y_i x_i \end{bmatrix};$$

a. Costruiamo la matrice 
$$\begin{bmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{bmatrix},$$
  
dove  $n = 6$ ;  $\sum x_i = \mathbf{1}' \cdot \mathbf{x} = 23$ ;  $\sum x_i^2 = \mathbf{x}' \cdot \mathbf{x} = 119$ ,  
sostituendo otteniamo 
$$\begin{bmatrix} 6 & 23 \\ 23 & 119 \end{bmatrix}$$

b. Troviamo l'inversa: 
$$\begin{bmatrix} 0.643 & -0.124 \\ -0.124 & 0.032 \end{bmatrix}$$

c. Troviamo 
$$\begin{bmatrix} \sum y_i = \mathbf{1}' \cdot \mathbf{y} = 27 \\ \sum y_i x_i = \mathbf{y}' \cdot \mathbf{x} = 128 \end{bmatrix};$$

137

## Regressione - soluzione

d. Infine: 
$$\begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} 0.643 & -0.124 \\ -0.124 & 0.032 \end{bmatrix} \begin{bmatrix} 27 \\ 128 \end{bmatrix} = \begin{bmatrix} 1.454 \\ 0.795 \end{bmatrix}.$$

La retta di regressione è dunque:  $\hat{y} = 1.454 + 0.795x$ .

2. Dai dati precedenti, calcola  $SQ_{TOT}$ ,  $SQ_{REG}$  e  $SQ_{ERR}$ .

a. Sappiamo che

$$SQ_{TOT} = SQ_{REG} + SQ_{ERR}$$

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

Li calcoleremo tutti e tre, per controllare l'esattezza dei calcoli

138

## Regressione - soluzione

b. Calcoliamo  $SQ_{TOT}$ :

$$\sum (y_i - \bar{y})^2 = (\mathbf{y} - n^{-1} \sum y_i \cdot \mathbf{1})' \cdot (\mathbf{y} - n^{-1} \sum y_i \cdot \mathbf{1}) = \left( \begin{bmatrix} 3 \\ 2 \\ 2 \\ 7 \\ 6 \\ 7 \end{bmatrix} - \begin{bmatrix} 4.5 \\ 4.5 \\ 4.5 \\ 4.5 \\ 4.5 \\ 4.5 \end{bmatrix} \right)' \cdot \left( \begin{bmatrix} 3 \\ 2 \\ 2 \\ 7 \\ 6 \\ 7 \end{bmatrix} - \begin{bmatrix} 4.5 \\ 4.5 \\ 4.5 \\ 4.5 \\ 4.5 \\ 4.5 \end{bmatrix} \right) = 29.5$$

c. Calcoliamo  $SQ_{REG}$ :

$$\begin{aligned} \sum (\hat{y}_i - \bar{y})^2 &= (\hat{\mathbf{y}} - \bar{\mathbf{y}})' \cdot (\hat{\mathbf{y}} - \bar{\mathbf{y}}) = \left\{ (a \cdot \mathbf{1} + b \cdot \mathbf{x}) - \bar{\mathbf{y}} \right\}' \cdot (\hat{\mathbf{y}} - \bar{\mathbf{y}}) = \\ &= \left\{ \left( \begin{bmatrix} 1.454 \\ 1.454 \\ 1.454 \\ 1.454 \\ 1.454 \\ 1.454 \end{bmatrix} + \begin{bmatrix} 1.589 \\ 2.383 \\ 0.795 \\ 3.178 \\ 3.973 \\ 6.357 \end{bmatrix} \right) - \begin{bmatrix} 4.5 \\ 4.5 \\ 4.5 \\ 4.5 \\ 4.5 \\ 4.5 \end{bmatrix} \right\}' \cdot \begin{bmatrix} -1.457 \\ -0.662 \\ -2.251 \\ 0.132 \\ 0.927 \\ 3.311 \end{bmatrix} = 19.468 \end{aligned}$$

139

## Regressione lineare multipla

4. I dati del vettore  $y$  precedente dipendono non solo dalla variabile indipendente  $x$  (d'ora in avanti,  $x_1$ ), ma anche dalle variabili indipendenti  $x_2$  e  $x_3$ :

$$\mathbf{x}_2 = \begin{bmatrix} 2 \\ 2 \\ 1 \\ 5 \\ 9 \\ 2 \end{bmatrix}; \mathbf{x}_3 = \begin{bmatrix} 3 \\ 7 \\ 2 \\ 6 \\ 8 \\ 9 \end{bmatrix}.$$

Utilizzando solo l'algebra lineare, calcolare i coefficienti parziali di regressione, calcolarne la significatività con il test- $t$  e calcolare la significatività del modello complessivo con la statistica  $F$ .

5. Confrontare il *modello ridotto*  $\hat{y} = a + b_1 x_1$  con il *modello completo*  $\hat{y} = a + b_1 x_1 + b_2 x_2 + b_3 x_3$ , utilizzando gli indici  $R^2$  e la statistica  $F$ .

141

## Regressione - soluzione

d. Calcoliamo  $SQ_{ERR}$ :

$$\sum (y_i - \hat{y})^2 = (\mathbf{y} - \hat{\mathbf{y}})' \cdot (\mathbf{y} - \hat{\mathbf{y}}) = \left( \begin{bmatrix} 3 \\ 2 \\ 2 \\ 7 \\ 6 \\ 7 \end{bmatrix} - \begin{bmatrix} 3.043 \\ 3.838 \\ 2.248 \\ 4.632 \\ 5.427 \\ 7.810 \end{bmatrix} \right)' \cdot \left( \begin{bmatrix} 3 \\ 2 \\ 2 \\ 7 \\ 6 \\ 7 \end{bmatrix} - \begin{bmatrix} 3.043 \\ 3.838 \\ 2.248 \\ 4.632 \\ 5.427 \\ 7.810 \end{bmatrix} \right) = 10.032$$

e. Controlliamo:

$$\begin{aligned} SQ_{TOT} &= SQ_{REG} + SQ_{ERR} \\ 29.5 &\cong 19.468 + 10.032 \end{aligned}$$

3. Calcoliamo il coefficiente di determinazione  $R^2$

$$R^2 = \frac{SQ_{REG}}{SQ_{TOT}} = \frac{19.468}{29.5} = 0.66$$

140

## Regressione multipla - soluzione

Noi sappiamo che

$$\underset{(n \times 1)}{\mathbf{Y}} = \underset{(n \times (k+1))}{\mathbf{X}} \underset{(k+1 \times 1)}{\boldsymbol{\beta}} + \underset{(n \times 1)}{\boldsymbol{\epsilon}}$$

e che

$$\underset{(k+1 \times 1)}{\mathbf{B}} = \left( \underset{(k+1 \times n)}{\mathbf{X}'} \underset{(n \times (k+1))}{\mathbf{X}} \right)^{-1} \underset{(k+1 \times n)}{\mathbf{X}'} \underset{(n \times 1)}{\mathbf{Y}}$$

$$\mathbf{y} = \begin{bmatrix} 3 \\ 2 \\ 2 \\ 7 \\ 6 \\ 7 \end{bmatrix}; \mathbf{X} = \begin{bmatrix} 1 & 2 & 2 & 3 \\ 1 & 3 & 2 & 7 \\ 1 & 1 & 1 & 2 \\ 1 & 4 & 5 & 6 \\ 1 & 5 & 9 & 8 \\ 1 & 8 & 2 & 9 \end{bmatrix}.$$

142

## Regressione multipla - soluzione

$$(\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} 1.1434 & 0.1243 & -0.0021 & -0.2479 \\ & 0.1693 & 0.0189 & -0.1439 \\ & & 0.0301 & -0.0301 \\ & & & 0.1551 \end{bmatrix}; \mathbf{X}'\mathbf{Y} = \begin{bmatrix} 27 \\ 128 \\ 115 \\ 180 \end{bmatrix}; \mathbf{B} = \begin{bmatrix} 1.93 \\ 1.29 \\ 0.40 \\ -0.65 \end{bmatrix}.$$

4(a). L'equazione di regressione multipla è quindi

$$\hat{y} = 1.93 + 1.29x_1 + 0.40x_2 - 0.65x_3$$

il vettore degli errori (o *residui*) è dato da

$$\mathbf{e} = \mathbf{y} - \hat{\mathbf{y}} = \begin{bmatrix} 3 \\ 2 \\ 2 \\ 7 \\ 6 \\ 7 \end{bmatrix} - \begin{bmatrix} 1 & 2 & 2 & 3 \\ 1 & 3 & 2 & 7 \\ 1 & 1 & 1 & 2 \\ 1 & 4 & 5 & 6 \\ 1 & 5 & 9 & 8 \\ 1 & 8 & 2 & 9 \end{bmatrix} \begin{bmatrix} 1.93 \\ 1.29 \\ 0.40 \\ -0.65 \end{bmatrix} = \begin{bmatrix} 3 \\ 2 \\ 2 \\ 7 \\ 6 \\ 7 \end{bmatrix} - \begin{bmatrix} 3.36 \\ 2.03 \\ 2.31 \\ 5.20 \\ 6.81 \\ 7.21 \end{bmatrix} \quad 143$$

## Regressione multipla - soluzione

4(c). Calcoliamo ora la significatività del modello completo con:

$$F_{(k, n-k-1)} = \frac{SQ_{REG_C}/k}{SQ_{ERR_C}/(n-k-1)} = \frac{SQ_{REG_C}}{SQ_{ERR_C}} \times \frac{(n-k-1)}{k}$$

Noi sappiamo che

$$n = 6; \quad k = 3;$$

$$SQ_{REG_C} = \sum (\hat{y}_i - \bar{Y})^2 = (\hat{\mathbf{y}} - \bar{\mathbf{Y}})'(\hat{\mathbf{y}} - \bar{\mathbf{Y}}) = ((b_0 \cdot \mathbf{1} + b_1 \cdot \mathbf{x}_1 + b_2 \cdot \mathbf{x}_2 + b_3 \cdot \mathbf{x}_3) - \bar{\mathbf{Y}})'(\hat{\mathbf{y}} - \bar{\mathbf{Y}}) = 25.344$$

$$SQ_{ERR_C} = \sum (y_i - \hat{y}_i)^2 = (\mathbf{y} - \hat{\mathbf{y}})'(\mathbf{y} - \hat{\mathbf{y}}) = 4.156;$$

$$F_{(3,2)} = \frac{25.344}{4.156} \times \frac{2}{3} = 4.065; \quad p > 0.05.$$

145

## Regressione multipla - soluzione

La varianza dei parametri di regressione è:

$$S_E^2 = \frac{\mathbf{e}'\mathbf{e}}{n-k-1} = \frac{4.156}{6-3-1} = 2.078$$

$$Var(a) = S_E^2 \left[ (\mathbf{X}'\mathbf{X})^{-1} \right]_{11} = 2.078 \times 1.1434 = 2.376$$

$$Var(b_1) = S_E^2 \left[ (\mathbf{X}'\mathbf{X})^{-1} \right]_{22} = 2.078 \times 0.1693 = 0.352$$

$$Var(b_2) = S_E^2 \left[ (\mathbf{X}'\mathbf{X})^{-1} \right]_{33} = 2.078 \times 0.0301 = 0.063$$

$$Var(b_3) = S_E^2 \left[ (\mathbf{X}'\mathbf{X})^{-1} \right]_{44} = 2.078 \times 0.1551 = 0.322$$

La statistica  $t$  (2 g.d.l) relativa al primo parametro (intercetta) risulta essere:

$$t = \frac{\mathbf{B}_1 - 0}{\sqrt{S_E^2 \left[ (\mathbf{X}'\mathbf{X})^{-1} \right]_{11}}} = \frac{1.93}{\sqrt{2.376}}$$

4(b). Il vettore di parametri di regressione trasformati in punti  $t$  si ottiene

come:

$$\mathbf{t} = \begin{bmatrix} \sqrt{1/2.376} & 0 & 0 & 0 \\ 0 & \sqrt{1/0.352} & 0 & 0 \\ 0 & 0 & \sqrt{1/0.063} & 0 \\ 0 & 0 & 0 & \sqrt{1/0.322} \end{bmatrix} \begin{bmatrix} 1.93 \\ 1.29 \\ 0.40 \\ -0.65 \end{bmatrix} = \begin{bmatrix} 1.93/\sqrt{2.376} \\ 1.29/\sqrt{0.352} \\ 0.40/\sqrt{0.063} \\ -0.65/\sqrt{0.322} \end{bmatrix}; \quad 144$$

...tutti con  $p > 0.05$

## Regressione multipla - soluzione

5. Confrontiamo il *modello ridotto* (senza  $\mathbf{x}_2$  e  $\mathbf{x}_3$ ;  $q = 2$ ) con il *modello completo* utilizzando gli indici  $R^2$  e la statistica  $F$ :

$$F_{(q, n-k-1)} = \frac{(R_C^2 - R_R^2)/q}{(1 - R_C^2)/(n-k-1)} = \frac{R_C^2 - R_R^2}{1 - R_C^2} \times \frac{(n-k-1)}{q}$$

Noi sappiamo che

$$n = 6; \quad k = 3; \quad q = 2$$

$$R_R^2 = \frac{SQ_{REG_R}}{SQ_{TOT}} = \frac{19.468}{29.5} = 0.66$$

$$R_C^2 = \frac{SQ_{REG_C}}{SQ_{TOT}} = \frac{25.344}{29.5} = 0.859$$

$$F_{(2,2)} = \frac{0.859 - 0.66}{1 - 0.859} \times \frac{2}{2} = 1.414; \quad p > 0.05.$$

146