

Psicometria con Laboratorio di SPSS 2

Regressione lineare multipla
(v. 1.7a, 7 novembre 2022)

Germano Rossi¹
germano.rossi@unimib.it

¹Dipartimento di Psicologia, Università di Milano-Bicocca

2017-18

- 1 Regressione lineare multipla
- 2 In SPSS
- 3 Correlazioni multiple e parziali

ATTENZIONE: Tutte le slide con una lettera nell'angolo destro del titolo, indicano: A = delle informazioni Avanzate da leggere successivamente dopo aver compreso le altre; M = una parte che utilizza l'algebra Matriciale che è possibile saltare.

1 Regressione lineare multipla

- Introduzione generale
- Influenze fra variabili
- Varianza spiegata o ampiezza dell'effetto


2 In SPSS

3 Correlazioni multiple e parziali

Regressione lineare multipla

- Analoga a quella semplice
- Una sola variabile dipendente (Y) da spiegare
- Due o più variabili indipendenti (X) predittive, esplicative

Regressione lineare semplice (1 dip, 1 indep)



Regressione lineare multipla (2 indep, 1 dip)

- a, b_0 , intercetta, costante
- b, b_1 b_2 ..., pendenza, coefficienti/parametri di regressione

Regressione come modello generale

All'equazione della retta

$$Y_i = \beta_0 + \beta_1 X_i \quad \text{oppure} \quad Y_i = a + bX_i \quad \text{se 1 VI}$$

possiamo aggiungere più variabili esplicative quantitative

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} \quad \text{se 2 VI}$$

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \beta_3 X_{3i} \quad \text{se 3 VI}$$

oppure variabili categoriali dicotomiche (0,1) [uso D per evidenziare]

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 D_{2i} \quad \text{se 1 Qt, 1 dicot}$$

e con un'interazione (con I=XD)

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 D_{2i} + \beta_3 I_{3i} \quad \text{se 1 Qt, 1 dicot, 1 inter}$$

Regressione multipla: caso per caso

Ipotizziamo di avere una Y e due X (X_1, X_2) l'equazione sarà:

$$Y_i = b_0 + b_1X_{1i} + b_2X_{2i} + e_i$$

Y	X_1	X_2	$Y = b_0 + X_{1i}b_1 + X_{2i}b_2 + e$
3	2	1	$3 = 1b_0 + 2b_1 + 1b_2 + e_1$
2	3	5	$2 = 1b_0 + 3b_1 + 5b_2 + e_2$
4	5	3	$4 = 1b_0 + 5b_1 + 3b_2 + e_3$
5	7	6	$5 = 1b_0 + 7b_1 + 6b_2 + e_4$
8	8	7	$8 = 1b_0 + 8b_1 + 7b_2 + e_5$

- Per ogni caso statistico, sostituiamo i valori nell'equazione generale
- La costante (b_0) viene idealmente moltiplicata per 1
- Per ogni caso statistico, sostituiamo i valori nell'equazione generale

Regressione multipla: caso per caso

Ipotizziamo di avere una Y e due X (X_1, X_2) l'equazione sarà:

$$Y_i = b_0 + b_1X_{1i} + b_2X_{2i} + e_i$$

Y	X_1	X_2	$Y = b_0 + X_{1i}b_1 + X_{2i}b_2 + e$
3	2	1	$3 = 1b_0 + 2b_1 + 1b_2 + e_1$
2	3	5	$2 = 1b_0 + 3b_1 + 5b_2 + e_2$
4	5	3	$4 = 1b_0 + 5b_1 + 3b_2 + e_3$
5	7	6	$5 = 1b_0 + 7b_1 + 6b_2 + e_4$
8	8	7	$8 = 1b_0 + 8b_1 + 7b_2 + e_5$

- Per ogni caso statistico, sostituiamo i valori nell'equazione generale
- La costante (b_0) viene idealmente moltiplicata per 1
- Per ogni caso statistico, sostituiamo i valori nell'equazione generale

Regressione multipla: caso per caso

Ipotizziamo di avere una Y e due X (X_1, X_2) l'equazione sarà:

$$Y_i = b_0 + b_1X_{1i} + b_2X_{2i} + e_i$$

Y	X_1	X_2	$Y = b_0 + X_{1i}b_1 + X_{2i}b_2 + e$
3	2	1	$3 = 1b_0 + 2b_1 + 1b_2 + e_1$
2	3	5	$2 = 1b_0 + 3b_1 + 5b_2 + e_2$
4	5	3	$4 = 1b_0 + 5b_1 + 3b_2 + e_3$
5	7	6	$5 = 1b_0 + 7b_1 + 6b_2 + e_4$
8	8	7	$8 = 1b_0 + 8b_1 + 7b_2 + e_5$

- Per ogni caso statistico, sostituiamo i valori nell'equazione generale
- La costante (b_0) viene idealmente moltiplicata per 1
- Per ogni caso statistico, sostituiamo i valori nell'equazione generale

Passando al matriciale, abbiamo vettori e matrici:

$$\begin{array}{c} \begin{bmatrix} 3 \\ 2 \\ 4 \\ 5 \\ 8 \end{bmatrix} \\ \\ 5 \times 1 \\ \mathbf{y} \end{array} = \begin{array}{c} \begin{bmatrix} 1 & 2 & 1 \\ 1 & 3 & 5 \\ 1 & 5 & 3 \\ 1 & 7 & 6 \\ 1 & 8 & 7 \end{bmatrix} \\ \\ 5 \times 3 \\ \mathbf{X} \end{array} \begin{array}{c} \begin{bmatrix} b_0 \\ b_1 \\ b_2 \end{bmatrix} \\ \\ 3 \times 1 \\ \mathbf{b} \end{array} + \begin{array}{c} \begin{bmatrix} e_1 \\ e_2 \\ e_3 \\ e_4 \\ e_5 \end{bmatrix} \\ \\ 5 \times 1 \\ \mathbf{e} \end{array}$$

- Ignoriamo gli errori (\mathbf{e})
- \mathbf{b} è il vettore dei parametri incogniti (non standardizzati)
- \mathbf{b}^* o β è il vettore dei parametri (standardizzati)
- In algebra, per trovare \mathbf{b} useremmo \mathbf{y}/\mathbf{X}
- ma in algebra matriciale la “divisione” diventa un’ “inversa” (indicata con $^{-1}$)

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

$$\left(\begin{matrix} \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 2 & 3 & 5 & 7 & 8 \\ 1 & 5 & 3 & 6 & 7 \end{bmatrix} \\ \begin{bmatrix} 1 & 2 & 1 \\ 1 & 3 & 5 \\ 1 & 5 & 3 \\ 1 & 7 & 6 \\ 1 & 8 & 7 \end{bmatrix} \end{matrix} \right)^{-1} \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 2 & 3 & 5 & 7 & 8 \\ 1 & 5 & 3 & 6 & 7 \end{bmatrix} \begin{bmatrix} 3 \\ 2 \\ 4 \\ 5 \\ 8 \end{bmatrix}$$

$$\begin{bmatrix} 5 & 25 & 22 \\ 25 & 151 & 130 \\ 22 & 130 & 120 \end{bmatrix}^{-1} \begin{bmatrix} 22 \\ 131 \\ 111 \end{bmatrix} = \begin{bmatrix} 0.50 \\ 1 \\ -0.25 \end{bmatrix} \begin{matrix} b_0 \\ b_1 \\ b_2 \end{matrix}$$


$$\hat{Y}_i = .50 + 1X_{1i} + (-.25)X_{2i}$$

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} N & \sum X_1 & \sum X_2 \\ \sum X_1 & \sum X_1^2 & \sum X_1 X_2 \\ \sum X_2 & \sum X_1 X_2 & \sum X_2^2 \end{bmatrix} \quad \mathbf{X}'\mathbf{y} = \begin{bmatrix} \sum Y \\ \sum X_1 Y \\ \sum X_2 Y \end{bmatrix}$$

Più in generale, date n variabili indipendenti, $\mathbf{X}'\mathbf{X}$ e $\mathbf{X}'\mathbf{y}$ diventeranno:

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} N & \sum X_1 & \cdots & \sum X_n \\ \sum X_1 & \sum X_1^2 & \cdots & \sum X_1 X_n \\ \cdots & \cdots & \cdots & \cdots \\ \sum X_n & \sum X_1 X_n & \cdots & \sum X_n^2 \end{bmatrix} \quad \mathbf{X}'\mathbf{y} = \begin{bmatrix} \sum Y \\ \sum X_1 Y \\ \cdots \\ \sum X_n Y \end{bmatrix}$$

Percorsi causali/relazionali: definizioni




$$Z \rightarrow Y$$

significa che Z spiega Y
e a è il valore dell'influenza

- **Influenza diretta** = percorso semplice ($Z \rightarrow Y = a$, $Z \rightarrow X = b$, $X \rightarrow Y = c$)
- **Influenza indiretta** = percorso composto ($Z \rightarrow X \rightarrow Y = bc$) con anche le eventuali covarianze
- Il valore di un'influenza indiretta è pari al prodotto delle influenze semplici ($b \cdot c$)

Percorsi causali/relazionali: definizioni




$$Z \rightarrow Y$$

significa che Z spiega Y
e a è il valore dell'influenza

- **Influenza diretta** = percorso semplice ($Z \rightarrow Y = a$, $Z \rightarrow X = b$, $X \rightarrow Y = c$)
- **Influenza indiretta** = percorso composto ($Z \rightarrow X \rightarrow Y = bc$) con anche le eventuali covarianze
- Il valore di un'influenza indiretta è pari al prodotto delle influenze semplici ($b \cdot c$)

Percorsi causali/relazionali: definizioni




$$Z \rightarrow Y$$

significa che Z spiega Y
e a è il valore dell'influenza

- **Influenza diretta** = percorso semplice ($Z \rightarrow Y = a$, $Z \rightarrow X = b$, $X \rightarrow Y = c$)
- **Influenza indiretta** = percorso composto ($Z \rightarrow X \rightarrow Y = bc$) con anche le eventuali covarianze
- Il valore di un'influenza indiretta è pari al prodotto delle influenze semplici ($b \cdot c$)

Percorsi causali/relazionali: definizioni




$$Z \rightarrow Y$$

significa che Z spiega Y
e a è il valore dell'influenza

- **Influenza diretta** = percorso semplice ($Z \rightarrow Y = a$, $Z \rightarrow X = b$, $X \rightarrow Y = c$)
- **Influenza indiretta** = percorso composto ($Z \rightarrow X \rightarrow Y = bc$) con anche le eventuali covarianze
- Il valore di un'influenza indiretta è pari al prodotto delle influenze semplici ($b \cdot c$)


Percorsi causali/relazionali: definizioni



$Z \rightarrow Y$
significa che Z spiega Y
e a è il valore dell'influenza

- **Influenza diretta** = percorso semplice ($Z \rightarrow Y = a$, $Z \rightarrow X = b$, $X \rightarrow Y = c$)
- **Influenza indiretta** = percorso composto ($Z \rightarrow X \rightarrow Y = bc$) con anche le eventuali covarianze
- Il valore di un'influenza indiretta è pari al prodotto delle influenze semplici ($b \cdot c$)

Percorsi causali/relazionali



$$r_{X_1Y} = b_1^* + b_2^* r_{X_1X_2}$$

$$r_{X_2Y} = b_2^* + b_1^* r_{X_1X_2}$$

Possiamo ricavare il valore di b_1^* e di b_2^*

Uso 1 anziché X_1 e 2 anziché X_2

$$b_1^* = r_{1Y} - r_{12} b_2^* = .65 - .50 b_2^*$$

$$b_2^* = r_{2Y} - r_{12} b_1^* = .70 - .50 b_1^*$$

La correlazione fra 2 variabili è la somma delle influenze dirette e indirette delle due variabili

Considerando che la correlazione di una variabile con se stessa è 1

$$r_{y1} = b_1^* + b_2^* r_{12} = b_1^* r_{11} + b_2^* r_{12} = b_1^* r_{11} + b_2^* r_{12}$$

$$r_{y2} = b_2^* + b_1^* r_{12} = b_2^* r_{22} + b_1^* r_{12} = b_1^* r_{12} + b_2^* r_{22}$$

$$\begin{bmatrix} r_{y1} \\ r_{y2} \end{bmatrix} = \begin{bmatrix} r_{11} & r_{12} \\ r_{12} & r_{22} \end{bmatrix} \begin{bmatrix} b_1^* \\ b_2^* \end{bmatrix}$$

$$\mathbf{r}_{yx} = \mathbf{R}_{xx} \mathbf{b}_{yx}^*$$

$$\mathbf{b}_{yx}^* = \mathbf{R}_{xx}^{-1} \mathbf{r}_{yx}$$

- Ci sono tre formule alternative

Dati grezzi	$\mathbf{b} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$	parametri non standardizzati
Varianze/covarianze	$\mathbf{b} = \mathbf{C}_{xx}^{-1}\mathbf{c}_{yx}$	parametri non standardizzati
Correlazioni	$\mathbf{b}^* = \mathbf{R}_{xx}^{-1}\mathbf{r}_{yx}$	parametri standardizzati

- \mathbf{C}_{xx} è la matrice delle varianze/covarianze fra le X
- \mathbf{c}_{yx} è il vettore delle covarianze fra la Y e le X
- \mathbf{R}_{xx} è la matrice delle correlazioni fra le X
- \mathbf{r}_{yx} è il vettore delle correlazioni fra la Y e le X

Calcoliamo

Y	X ₁	X ₂	Y ²	X ₁ ²	X ₂ ²	X ₁ Y	X ₂ Y	X ₁ X ₂	
3	2	1	9	4	1	6	3	2	
2	3	5	4	9	25	6	10	15	
4	5	3	16	25	9	20	12	15	
5	7	6	25	49	36	35	30	42	
8	8	7	64	64	49	64	56	56	
22	25	22	118	151	120	131	111	130	somme
4,4	5	4,4							medie
			5,3	6,5	5,8	5,25	3,55	5,0	var/cov
						.894	.640	.814	cor

$$var = \frac{\sum x^2 - \frac{(\sum x)^2}{N}}{N - 1} \quad cov = \frac{\sum xy - \frac{\sum x \sum y}{N}}{N - 1} \quad cor = \frac{cov(xy)}{\sqrt{var(x)var(y)}}$$

Calcolare a mano i parametri di una regr. multipla (b_0, b_1, b_2) è complesso, usiamo il calcolo matriciale

Esempio con covarianze: parametri NON standardizzati **M**

Varianze e covarianze calcolate con $N - 1$

$$\mathbf{C}_{xx} = \begin{bmatrix} 6.5 & 5.0 \\ 5.0 & 5.8 \end{bmatrix} \quad \mathbf{c}_{yx} = \begin{bmatrix} 5.25 \\ 3.55 \end{bmatrix}$$

$$\frac{1}{12.7} \begin{bmatrix} 5.8 & -5.0 \\ -5.0 & 6.5 \end{bmatrix} \begin{bmatrix} 5.25 \\ 3.55 \end{bmatrix} = \begin{bmatrix} 1.00 \\ -0.25 \end{bmatrix} \leftarrow \begin{matrix} b_1 \\ b_2 \end{matrix}$$

$$b_0 = \bar{Y} - \sum (b_i \bar{X}_i) = 4.4 - 1 \cdot 5 - (-.25 \cdot 4.4) = 0.5$$

L'equazione finale per calcolare le stime per ogni caso è:

$$\hat{Y}_i = .50 + 1X_{1i} + (-.25)X_{2i}$$

$$\mathbf{R}_{xx} = \begin{bmatrix} 1 & .814 \\ .814 & 1 \end{bmatrix} \quad \mathbf{r}_{yx} = \begin{bmatrix} .894 \\ .640 \end{bmatrix}$$

$$\frac{1}{0.337} \begin{bmatrix} 1 & -.814 \\ -.814 & 1 \end{bmatrix} \begin{bmatrix} .894 \\ .640 \end{bmatrix} = \begin{bmatrix} 1.107 \\ -0.261 \end{bmatrix} \begin{matrix} \leftarrow b_1^* \\ \leftarrow b_2^* \end{matrix}$$

$$b_0 = 0$$

$$z_{\hat{Y}_i} = 1.107z_{X_{1i}} + (-.261)z_{X_{2i}}$$

Standardizzare/destandardizzare

Con i dati dell'esempio precedente

$$b_{yx_i} = b_{yx_i}^* \frac{s_y}{s_{x_i}} \quad 1 = 1.107 \frac{\sqrt{5.3}}{\sqrt{6.5}} \quad -0.25 = -0.261 \frac{\sqrt{5.3}}{\sqrt{5.8}}$$

$$b_{yx_i}^* = b_{yx_i} \frac{s_{x_i}}{s_y} \quad 1.107 = 1 \frac{\sqrt{6.5}}{\sqrt{5.3}} \quad -0.261 = -0.25 \frac{\sqrt{5.8}}{\sqrt{5.3}}$$

Proporzione di varianza spiegata

$$\begin{aligned} R^2 &= (r_{y\hat{y}})^2 = \frac{\textit{spiegata}}{\textit{totale}} = \frac{\sum(\hat{Y} - \bar{Y})^2}{\sum(Y - \bar{Y})^2} = \frac{SQ_m}{SQ_t} = \\ &= \frac{\sum(Y - \bar{Y})^2 - \sum(Y - \hat{Y})^2}{\sum(Y - \bar{Y})^2} = \\ &= \underbrace{r_{y1}b_{1.2}^*}_{\text{con 2 X}} + \underbrace{r_{y2}b_{2.1}^*}_{\text{generico}} = \sum(r_{yi}b_i^*) \end{aligned}$$

$$\mathbf{r}_{yx} = \begin{bmatrix} .894 \\ .640 \end{bmatrix} \quad \mathbf{b}^* = \begin{bmatrix} 1.107 \\ -0.261 \end{bmatrix} \quad R^2 = (.894 \cdot 1.107) + (.640 \cdot -.261)$$

Proporzione di varianza spiegata o ampiezza dell'effetto

Anche se R^2 viene spesso utilizzato per stimare la bontà di una regressione multipla

- R^2 è semplicemente una proporzione (varianza comune / varianza totale)
- $R^2 \times 100$ è la % di varianza spiegata dal modello
- R^2 non è un'ampiezza dell'effetto
- Ciò nonostante, una versione di R^2 (chiamata eta quadro, η^2) viene spesso interpretata come se fosse un'ampiezza dell'effetto, anche se è un po' distorta.
- altri tentativi di creare una vera misura di ampiezza dell'effetto sono: ω (omega) e f

- $R^2 = \eta^2 = \frac{SQ_m}{SQ_t}$
- $\omega = \frac{SQ_m + df_m \times MQ_e}{SQ_t + MQ_e}$
- $f = \frac{R^2}{1 - R^2}$ proposta da Cohen (1988)

dove SQ_M = Somma quadrati dell'effetto; SQ_t = Somma quadrati totale
 df_m gradi di libertà dell'effetto; MQ_e media dei quadrati dell'errore

Test di significatività

Sono i test che facciamo per verificare i passaggi dell'analisi

- a) un test globale: che include tutte le variabili (tramite Anova)

Se il test globale è significativo

- b) un test per ciascuna variabile indipendente (tramite Anova o t-test)

- Anche se il modello globale è significativo, questo non significa che tutte le X siano significativamente associate a Y

Nel **test globale** si fa un confronto fra il modello studiato e il modello nullo

nullo (ristretto)	$Y = b_0 + e$	gdl=N-1
completo	$Y = b_0 + b_1X_1 + b_2X_2 + e$	gdl=N-3

con N=numero di soggetti; 1 e 3 sono il numero di parametri

L'ipotesi nulla è $H_0: b_1 = b_2 = 0$

Usiamo la statistica F di Snedecor (rapporto di varianze) tramite un'analisi della varianza (Anova)

Se è significativa, c'è una relazione consistente fra le X e la Y; la regressione ha senso. **N.B.:** In genere, è significativa perché nel modello nullo, b_0 equivale alla media.

$$F = \frac{(R_f^2 - R_r^2)/(d_f - d_r)}{(1 - R_f^2)/d_f}$$

$$= \frac{\sum(Y - \bar{Y})^2 - \sum(Y - \hat{Y})^2/(d_r - d_f)}{\sum(Y - \hat{Y})^2/d_f}$$

$$= \frac{R_f^2/k}{(1 - R_f^2)/(N - k - 1)}$$

vale anche per i test parziali; f=full (completo); r=ristretto [$R^2 = 0$ per il modello nullo]

k=numero di variabili indipendenti (X)

R^2 tende ad aumentare al numero delle X, quindi viene “aggiustato”

$$R_{Adj}^2 = R^2 - (1 - R^2) \frac{k}{N - k - 1}$$

Test globale: varianza spiegata in Spss

Riepilogo del modello

Modello	R	R-quad	R-quad corr	Err. std. stima
1	,908(a)	0,824	0,821	14,87675

a. Stimatori: (Costante), rwait, oEsSoc, oEsPers, Pacific, olntrins, Ricerca

b. Variabile dipendente: Fondam

- La variabile Fondam viene spiegata da 6 variabili
- R è la correlazione fra tutte le variabili X e la Y (correlazione multipla)
- R-quad è la correlazione al quadrato (R^2)
- R-quad corr è la versione corretta dell' R^2

Test globale: esempio in Spss

ANOVA(b)

Modello	Somma quad.	df	Media quad.	F	Sig.
1 Regress.	290.770,441	6	48.461,740	218,969	,000(a)
Residuo	61.968,960	280	221,318		
Totale	352.739,401	286			

a. Stimatori: (Costante), rwait, oEsSoc, oEsPers, Pacific, oIntrins, Ricerca

b. Variabile dipendente: Fondam

$$F = \frac{.824/6}{(1 - .824)/(287 - 6 - 1)} = 218.484 \quad F = \frac{48.461,740}{221,318} = 218,969$$

$$R^2 = .824$$

ristretto	$Y = b_0 + b_1X_1 + e$	gdl=N-2
-----------	------------------------	---------

completo	$Y = b_0 + b_1X_1 + b_2X_2 + e$	gdl=N-3
----------	---------------------------------	---------

con N=numero di soggetti; 2 e 3 sono il numero di parametri

L'ipotesi nulla è $H_0: b_2 = 0$

Potremmo usare ancora la statistica F di Snedecor (rapporto di varianze)

La maggior parte dei programmi utilizza un semplice t-test. Se il test è significativo, la X_n considerata, può stare nel modello, altrimenti si dovrebbe togliere.

$$t = \frac{b_i}{s_{y.i}} = \frac{\text{parametro}}{\text{err. della stima}}$$

Test per ciascuna X: esempio in Spss

Coefficienti(a)

Modello	Coef. non stand.		Coef. stand. Beta	t	Sig.
	B	Err. std.			
1 (Costante)	66,265	14,455		4,584	0,000
Pacific	-0,383	0,106	-0,104	-3,619	0,000
oIntrins	2,195	0,177	0,437	12,385	0,000
oEsPers	0,351	0,365	0,028	0,962	0,337
oEsSoc	0,179	0,366	0,013	0,489	0,625
Ricerca	-0,456	0,058	-0,306	-7,845	0,000
rwait	0,702	0,102	0,247	6,880	0,000


a. Variabile dipendente: Fondam

$$t = \frac{2,195}{0,177} = 12,385$$

Ci sono 2 variabili che non servono ($p > .05$): oEsPers e oEsSoc

Il **Coef. stand.** è la relazione della X con la Y depurata del contributo delle altre


La situazione ideale per una regressione multipla dovrebbe essere: ogni X è altamente correlata con Y , ma le X non sono correlate fra loro



	X_1	X_2	X_3
Y	.60	.50	.70
X_1		.20	.30
X_2			.20

- Idealmente, le correlazioni tra le X , dovrebbero essere 0
- in questo modo b^* coinciderà con r e non con r parzializzato
- è una situazione che capita raramente

Spesso, due o più X sono correlate fra loro



	X_1	X_2	X_3
Y	.60	.50	.70
X_1		.70	.30
X_2			.20

- Quando due variabili X o più, sono tra loro correlate (moderatamente o più), parliamo di *multicollinearità*
- che può essere più o meno grave

Problemi

- Fa aumentare l'errore standard della stima
- limita la R multipla: se $A \leftrightarrow B$, ciascuna spiegherebbe una certa parte di Y, ma se A e B spiegano una stessa parte di varianza....
- l'effetto dei predittori si confonde: se A viene usato per prima, B non spiega più niente (e viceversa)
- aumenta la varianza e l'instabilità dell'equazione

Riconoscere la collinearità

- *Dopo aver deciso il modello da studiare:*
- Ispezione della matrice di correlazione
- Statistiche della collinearità

- **Variance inflation factor (VIF)**
- Indice di **Tolleranza**: $(1/VIF)$

Interpretazione (non ci sono valori "significativi")

- $VIF > 10$ (c'è multicollinearità)

- $VIF > 1$ (è possibile che ci sia)
- Tolleranza $< .1$ (grossi problemi)
- Tolleranza $< .2$ (potenzialmente problematico)
- $VIF \leq 1$ **OK**;
- Tolerance $\geq .2$ **OK**

Coefficienti^a

Modello		Coefficienti non standardizzati		Coefficienti standardizzati			Statistiche di collinearità	
		B	Errore standard	Beta	t	Sign.	Tolleranza	VIF
1	(Costante)	27,841	2,500		11,138	,000		
	SWLS	,207	,066	,259	3,125	,002	,647	1,546
	RIFAcet	,533	,137	,357	3,888	,000	,530	1,888
	DERSTOT	-,082	,018	-,338	-4,445	,000	,771	1,297

a. Variabile dipendente: RSE

Come diminuire la multicollinearità

- combinare fra loro i predittori altamente correlati (ad esempio sommandoli)
- eliminare un predittore molto correlato con un altro
- fra più predittori altamente correlati, eliminare quello meno correlato con la Y
- se ci sono molti predittori altamente correlati, usare un'analisi delle componenti principali per ridurre il numero delle X

Matrice di covarianze

	Y	G	H	V	W
Y	4.41				
G	1.89	1.44			
H	1.26	0.96	2.25		
V	1.96	0	0	4.00	
W	0.63	0	0	0.80	1

- Notiamo che G e H non correlano con V e W
- Quindi se calcolo $\hat{Y} = b_0 + b_1 H + b_2 V$ troverò esattamente gli stessi parametri di $\hat{Y} = b_0 + b_1 H$ e di $\hat{Y} = b_0 + b_2 V$

usando il calcolo matriciale

$$\begin{bmatrix} 2.25 & 0 \\ 0 & 4.0 \end{bmatrix}^{-1} \begin{bmatrix} 1.26 \\ 1.96 \end{bmatrix} = \begin{bmatrix} 0.56 \\ 0.49 \end{bmatrix}$$

Ipotizzando due regressioni semplici (separate):

$$b_H = \frac{\text{cov}(YH)}{\text{var}(H)} = \frac{1.26}{2.25} = 0.56 \quad b_V = \frac{1.96}{4} = 0.49$$

- **Usare la teoria:** Si usano solo variabili teoricamente sensate; la sensatezza può essere ricavata, oltre che dalla logica, da una ricerca bibliografica

In SPSS, possiamo usare diverse modalità di selezione:

- *Standard* (Inserisci): Tutte le variabili vengono inserite insieme (e poi andranno eliminate manualmente)
- (*Gerarchica*) Seguendo la teoria, si decidono i blocchi da utilizzare e vanno inserimenti per blocchi separati
- Metodi semi-automatici sequenziali (avanti, indietro, per passi)

Metodi semi-automatici sequenziali

- Il software seleziona le variabili in base a determinati criteri
- *Forward* (Avanti): Le variabili X vengono inserite una alla volta dal software, iniziando con la correlazione fra X_n e Y più alta, poi si prosegue con la seconda più alta e avanti così fino a che le variabili “aggiungono” un contributo significativo ($p < .05$)
- *Backward* (Indietro): Vengono inserite tutte e poi cancellate una alla volta se non significative ($p > .05$)
- *Stepwise* (a passi): Inizia con un blocco di variabili e poi vengono inserite o tolte una alla volta

Inserimento dei predittori: Inserisci

- metodo **standard** o *Inserisci*: Tutte le X vengono inserite assieme e tutti i coefficienti di regressione (B o β) stimati contemporaneamente (come negli esempi che abbiamo calcolato con 2 X)

Coefficienti^a

Modello		Coefficienti non standardizzati		Coefficienti standardizzati		Statistiche di collinearità		
		B	Errore standard	Beta	t	Sign.	Tolleranza	VIF
1	(Costante)	7,846	2,432		3,226	,002		
	INTRINS	,311	,065	,350	4,766	,000	,807	1,239
	ESTRPERS	1,113	,194	,424	5,735	,000	,796	1,256
	QUEST	-,043	,023	-,150	-1,881	,062	,680	1,471

a. Variabile dipendente: PosCOP

Inserimento dei predittori: Avanti

- **Forward** o *In avanti*: Le variabili X vengono inserite una alla volta (in genere la X con la correlazione XY più alta) e vengono poi calcolate le correlazioni parziali e i test di significatività di tutte le altre.
- Una nuova variabile viene inserita se risulta statisticamente associata al modello
- Ci si ferma quando non ci sono più variabili significative

Coefficienti^a

Modello		Coefficiente non standardizzati		Coefficiente standardizzati		Statistiche di collinearità		
		B	Errore standard	Beta	t	Sign.	Tolleranza	VIF
1	(Costante)	9,216	1,504		6,127	,000		
	ESTRPERS	1,501	,198	,572	7,566	,000	1,000	1,000
2	(Costante)	4,320	1,566		2,758	,007		
	ESTRPERS	1,259	,180	,479	7,000	,000	,947	1,055
	INTRINS	,358	,061	,403	5,883	,000	,947	1,055

a. Variabile dipendente: PosCOP

Inserimento dei predittori: Indietro

- **Backword** o *Indietro*: Le X vengono inserite tutte assieme e poi piano piano tolte se non risultano significative al t-test
- Ci si ferma quando tutte le non significative sono state tolte

Coefficienti^a

Modello		Coefficients non standardizzati		Coefficienti standardizzati		Statistiche di collinearità		
		B	Errore standard	Beta	t	Sign.	Tolleranza	VIF
1	(Costante)	7,846	2,432		3,226	,002		
	INTRINS	,311	,065	,350	4,766	,000	,807	1,239
	ESTRPERS	1,113	,194	,424	5,735	,000	,796	1,256
	QUEST	-,043	,023	-,150	-1,881	,062	,680	1,471
2	(Costante)	4,320	1,566		2,758	,007		
	INTRINS	,358	,061	,403	5,883	,000	,947	1,055
	ESTRPERS	1,259	,180	,479	7,000	,000	,947	1,055

a. Variabile dipendente: PosCOP

Inserimento dei predittori: a passi

- **Stepwise** o *per passi*: Si parte con “alcune” variabili X o con la X maggiormente associata alla Y
- Le altre X vengono inserite, tolte o ignorate a seconda della loro importanza e significatività statistica aggiuntiva
- Il modello finale identificato “dovrebbe” essere il migliore (ma è molto legato alle caratteristiche del campione...)


Ordine dei predittori

- Se le variabili X sono pochissimo correlate fra loro, l'ordine ha poca importanza
- Se sono correlate, usare le variabili maggiormente associate ad Y in letteratura
- Inserendole nell'ordine decrescente di efficacia indicata in letteratura
- **Preferibilmente**, usare l'approccio gerarchico
- Si inseriscono nel primo blocco le variabili maggiormente associate in letteratura/teoria
- successivamente si inseriscono altre variabili (in blocchi successivi)

- 1 Regressione lineare multipla
 - Introduzione generale
 - Influenze fra variabili
 - Varianza spiegata o ampiezza dell'effetto
- 2 In SPSS
- 3 Correlazioni multiple e parziali


In SPSS

- Analizza | Regressione | Lineare...
- Trasferite in Dipendente la variabile che volete spiegare (la Y)
- Trasferite in Indipendenti tutte le variabili che volete usare per spiegare (le diverse X)




In SPSS

- Per una **regressione standard**: verificare che Metodo sia impostato su Inserisci
- Per una **forward**: impostare Metodo su In avanti
- Per una **backward**: impostare Metodo su All'indietro
- Per una **stepwise**: impostare Metodo su Per passi (v.24)




In SPSS

- Click-ate su **Statistiche...**
- Selezionate almeno: *Diagnostiche di collinearità* e *Correlazioni di ordine zero e parziali*
- A piacere selezionate *Intervalli di confidenza*
- Poi **Continua** e **OK**



- 1 Regressione lineare multipla
 - Introduzione generale
 - Influenze fra variabili
 - Varianza spiegata o ampiezza dell'effetto
- 2 In SPSS
- 3 Correlazioni multiple e parziali

Correlazioni multiple e parziali



- Le intersezioni dei cerchi rappresentano le covarianze in comune fra le diverse variabili
- Con tre variabili, R^2 corrisponde a $(a + b + c)$ cioè la varianza che Y ha in comune con X_1 e X_2
- la correlazione multipla è quindi $\sqrt{R^2} = \sqrt{a + b + c}$; tutto il resto dell'area di Y è la varianza non spiegata $(1 - R^2)$
- Correlazione **parziale**: sovrapposizione fra Y e X_1 ($\sqrt{a + c}$) o fra Y e X_2 ($\sqrt{b + c}$)
- Correlazione **semiparziale**: solo la parte unica di sovrapposizione fra Y e X_1 (\sqrt{a}) o fra Y e X_2 (\sqrt{b})

Correlazione multipla

- È la correlazione di una variabile (Y) con 2 o più variabili (X_1, X_2, \dots) contemporaneamente (oscilla fra -1 e $+1$)

$$R = \sqrt{\frac{r_{12}^2 + r_{13}^2 - 2r_{12}r_{13}r_{23}}{1 - r_{23}^2}}$$

dove

r_{12} è la correlazione fra le variabili 1 e 2;

r_{13} fra la 1 e la 3... e

$r_{1.23}$ è la correlazione multipla (R)

r	1-RSE	2-SWLS
2-SWLS	.520	-
3-RifAccet	.634	.593

$R =$

$$\sqrt{\frac{.520^2 + .634^2 - 2 \times .520 \times .634 \times .593}{1 - .593^2}} \\ = .659$$

In SPSS si ottiene solo come sottoprodotto della regressione lineare multipla

Correlazione parziale

- È la correlazione di due variabili a cui viene “tolta” (contemporaneamente) l’influenza di una terza variabile.
- Es. correlazione fra “numero di parole conosciute” e “intelligenza” parzializzata in base all’età (tolto il contributo dell’età). Più l’età è correlata con una delle due, più la correlazione diminuirà.

$$pr_{12.3} = r_{12.3} = \frac{r_{12} - r_{13}r_{23}}{\sqrt{(1 - r_{13}^2)(1 - r_{23}^2)}}$$

dove

r_{12} è la correlazione fra le variabili 1 e 2;

r_{13} fra la 1 e la 3... e

$r_{12.3}$ è la correlazione fra 1 e 2 parzializzata sulla 3

$$\begin{aligned} R_p &= \frac{.520 - .634 \times .593}{\sqrt{(1 - .634^2)(1 - .593^2)}} \\ &= .231 \end{aligned}$$

In SPSS si ottiene in *Correlazione parziale* o in *Regressione lineare multipla*

Correlazione semi-parziale

- È la correlazione fra due variabili, ma solo ad una delle due è stato tolto il contributo di una terza.
- Es. correlazione fra “numero di parole conosciute” e “intelligenza”. La parzializzazione in base all'età viene attuata solo con il numero di parole.

$$sr_{12.3} = r_{1(2.3)} = \frac{r_{12} - r_{13}r_{23}}{\sqrt{1 - r_{23}^2}}$$

$$R_{sp} = \frac{.520 - .634 \times .593}{\sqrt{1 - .593^2}} = .178$$

dove r_{12} è la correlazione fra le variabile 1 e 2, r_{13} fra la prima e la terza e così via

In SPSS si ottiene solo in *Regressione lineare multipla*

Correlazioni parziali in SPSS

- 1 Analizza | Correlazione | Parziale...
 - 2 Analizza | Regressione | Lineare..., bottone Statistiche, segnare Correlazioni di ordine zero e parziale
-
- 1 Calcola la correlazione di più variabili, parzializzate su un'altra variabile (identica per tutte)
 - 2 Mentre effettua una regressione multipla, calcola la correlazione (ordine 0) fra ogni singola indipendente con la Y e quindi parzializza questa correlazione con tutte le altre indipendenti (parziale e semiparziale [parziale indipendenti])

Correlazioni parziali in SPSS

Riepilogo del modello

Modello	R	R- quadrato	R- quadrato adattato	Errore std. della stima
1	.659^a	,434	,425	3,306

a. Preditton. (costante), RIFAcct, SWLS

Coefficienti^a

Modello		Coefficients non standardizzati		Coefficient i standardiz zati		
		B	Errore standard	Beta	t	Sign.
1	(Costante)	19,549	1,551		12,607	,000
	SWLS	,178	,070	,223	2,559	,012
	RIFAcct	,744	,129	,502	5,767	,000

a. Variabile dipendente: RSE

95,0% Intervallo di
confidenza per B

Limite inferiore	Limite superiore	Correlazioni		Statistiche di collinearità		
		Ordine zero	Parziale	Parte	Tolleranza	VIF
16,477	22,620					
,040	,316	,520	,232	,179	,649	1,542
,489	1,000	,634	,474	,404	,649	1,542

Correlazioni

	RSE	SWLS	RIFAcct
Correlazione di Pearson	1,000	,520	,634
	RSE	,520	1,000
	SWLS	,634	,593
	RIFAcct	,593	1,000

$$R = \sqrt{\frac{.520^2 + .634^2 - 2 \times .520 \times .634 \times .593}{1 - .593^2}} = \mathbf{.659}$$

$$R_p = \frac{.520 - .634 \times .593}{\sqrt{(1 - .634^2)(1 - .593^2)}} = \mathbf{.231}$$

$$R_{sp} = \frac{.520 - .634 \times .593}{\sqrt{1 - .593^2}} = \mathbf{.178}$$

Residui

- I residui ($e = Y - \hat{Y}$) dovrebbero essere dispersi casualmente attorno a Y
- Se **non** sono dispersi casualmente, esiste un'altra variabile X che può spiegarne una parte, oppure la relazione non è lineare

