

## Psicomетria 1 (023-PS)

Michele Grassi  
mgrassi@units.it

Università di Trieste

Lezione 24

Sommario

### Sommario

Parte 3 – Associazione e causalità

Psicomетria 2 - p. 1/68

Parte 3 – Associazione e causalità

Psicomетria 2 - p. 2/68

### Sommario

Sommario

Il materiale coperto è contenuto nel capitolo 10 del testo di Agresti e Finlay (2012)

- Tipi di indagine
- Associazione e causalità
- Controllo statistico
- Relazioni spurie
- Variabili soppressorie
- Variabili intervenienti
- Cause multiple
- Interazioni tra variabili

Tipi fondamentali di indagine  
Studi sperimentali  
Illustrazione  
Studi osservazionali  
Studi osservazionali  
Limiti degli studi osservazionali

### Tipi fondamentali di indagine

Parte 3 – Associazione e causalità

Psicomетria 2 - p. 3/68

Parte 3 – Associazione e causalità

Psicomетria 2 - p. 4/68

### Tipi fondamentali di indagine

Si distinguono due tipi fondamentali di indagine

1. gli esperimenti
2. gli studi osservazionali.

Tipi fondamentali di indagine  
Studi sperimentali  
Illustrazione  
Studi osservazionali  
Studi osservazionali  
Limiti degli studi osservazionali

### Studi sperimentali

- Negli **esperimenti** il fenomeno oggetto di studio è sotto il controllo del ricercatore. Si studia l'effetto di uno o più trattamenti sulle unità sperimentali.
- Nel caso più semplice, i soggetti vengono assegnati casualmente dal ricercatore al gruppo di trattamento o al gruppo di controllo. L'obiettivo è comparare gli effetti del trattamento sulla risposta.
- La randomizzazione consente di produrre dei gruppi in cui tutte le altre variabili, anche quelle non misurate, hanno approssimativamente la stessa distribuzione e quindi sono comparabili.
- Le differenze sistematiche nelle risposte sono attribuite all'effetto del trattamento.

Tipi fondamentali di indagine  
Studi sperimentali  
Illustrazione  
Studi osservazionali  
Studi osservazionali  
Limiti degli studi osservazionali

Parte 3 – Associazione e causalità

Psicomетria 2 - p. 5/68

Parte 3 – Associazione e causalità

Psicomетria 2 - p. 6/68

## Illustrazione

**Illustrazione.** Nell'esperimento sull'efficacia di un farmaco, per esempio, i pazienti vengono assegnati in maniera casuale al gruppo di trattamento o al gruppo di controllo.

Né i pazienti né i ricercatori sanno a quale gruppo appartengono i pazienti (esperimento *double-blind*).

I gruppi sono in tutto confrontabili tranne per la modalità del trattamento, e quindi eventuali differenze nella risposta non possono essere dovute ad altro che al trattamento.

Tipi fondamentali di  
indagine  
Studi sperimentali  
**Illustrazione**  
Studi  
osservazionali  
Studi  
osservazionali  
Limiti degli studi  
osservazionali

## Studi osservazionali

■ Negli **studi osservazionali** il fenomeno oggetto di studio esiste in natura e non è controllabile dallo sperimentatore.

■ I soggetti si auto-assegnano al gruppo di controllo o al trattamento: il ricercatore deve osservare passivamente ciò che accade.

Tipi fondamentali di  
indagine  
Studi sperimentali  
**Illustrazione**  
Studi  
osservazionali  
Studi  
osservazionali  
Limiti degli studi  
osservazionali

Parte 3 – Associazione e causalità

Psicometria 2 - p. 7/68

Parte 3 – Associazione e causalità

Psicometria 2 - p. 8/68

## Studi osservazionali

**Illustrazione.** studio sugli effetti del fumo.

- **Trattamento:** fumo.
- **Risposta:** sviluppo malattie respiratorie.
- **Auto-selezione** degli individui al trattamento: fumatori vs non fumatori (controllo).

Tipi fondamentali di  
indagine  
Studi sperimentali  
**Illustrazione**  
Studi  
osservazionali  
Studi  
osservazionali  
Limiti degli studi  
osservazionali

## Limiti degli studi osservazionali

■ Negli studi osservazionali la mancanza di controllo sull'assegnazione dei trattamenti fa sì che i gruppi non siano mai **totalmente comparabili** e quindi eventuali differenze nella risposta sono attribuibili

- ◆ al fumo e/o
- ◆ ad altri fattori non controllati (fattori ereditari, età, sesso).

■ Anche se con metodi statistici è possibile misurare le differenze nella risposta aggiustate per eventuali non comparabilità nei gruppi trattati, agli studi osservazionali non possono essere assegnate interpretazioni di natura causale.

Tipi fondamentali di  
indagine  
Studi sperimentali  
**Illustrazione**  
Studi  
osservazionali  
Studi  
osservazionali  
Limiti degli studi  
osservazionali

Parte 3 – Associazione e causalità

Psicometria 2 - p. 9/68

Parte 3 – Associazione e causalità

Psicometria 2 - p. 10/68

## Associazione e causalità

Associazione e  
causalità

## Associazione e causalità

L'associazione tra due o più variabili non prova l'esistenza di un rapporto di tipo causale.

- Tra due variabili può esserci associazione e non causalità.
- Il concetto di causalità è difficile e controverso.

Associazione e  
causalità

Parte 3 – Associazione e causalità

Psicometria 2 - p. 11/68

Parte 3 – Associazione e causalità

Psicometria 2 - p. 12/68

## Associazione e causalità

Associazione e causalità

- La nozione di causalità riveste un ruolo centrale nella ricerca scientifica. Tutti sono familiari con il concetto di "nesso causale", almeno in un senso informale.
  - ◆ Es. essere esposti ad un virus *causa* l'influenza.
- Non tutti sanno però come un possibile nesso causale possa essere sottoposto a verifica in maniera rigorosa.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 13/68

## Associazione e causalità

Associazione e causalità

- Tale verifica è particolarmente problematica in psicologia dove le relazioni tra le variabili hanno una natura probabilistica piuttosto che deterministica.
- Es. cosa causa la delinquenza giovanile?
    - ◆ Essere poveri?
    - ◆ Provenire da famiglie con un solo parente?
    - ◆ La mancanza di educazione morale e religiosa?
    - ◆ Fattori genetici?
    - ◆ Una combinazione di questi e altri fattori?

Parte 3 – Associazione e causalità

Psicometria 2 - p. 14/68

## Associazione e causalità

Associazione e causalità

- Affinchè possa essere considerata di natura causale, una relazione tra due variabili deve soddisfare tre criteri.
1. Esiste "**covarianzione**" tra la variabile dipendente e la variabile indipendente.
  2. Esiste una **sequenza temporale** tra le variabili. Il cambiamento nella presunta variabile indipendente deve precedere il cambiamento nella presunta variabile dipendente.
  3. Assenza di **spiegazioni alternative**: Es. l'associazione fra le due variabili potrebbe essere il prodotto di una causa comune ad entrambe (relazione spuria).

Parte 3 – Associazione e causalità

Psicometria 2 - p. 15/68

## Associazione e causalità

Associazione e causalità

- Diciamo che X *causa* Y se:
- esiste una relazione tra X e Y ;
  - la relazione è asimmetrica (una variazione di X causa una variazione di Y , ma non viceversa);
  - una variazione di X ha come risultato una variazione di Y quali che siano le influenze di altri fattori.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 16/68

## Associazione e causalità

Associazione e causalità

- Se tutti questi tre criteri risultano soddisfatti, allora si conclude che le evidenze empiriche vanno a sostegno dell'esistenza di un nesso causale.
- Se uno o più dei criteri precedenti non sono soddisfatti, allora si conclude che non vi è nesso causale.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 17/68

## Associazione e causalità

Associazione e causalità

- Non è mai possibile provare che una prima variabile sia la causa di una seconda variabile, dato che i nessi causali sono inferiti dallo sperimentatore e mai osservati direttamente in quanto tali.
- L'unica cosa che il ricercatore può fare è falsificare le ipotesi di natura causale.
- Un'ipotesi causale può essere dimostrata falsa se le evidenze empiriche non soddisfano almeno uno dei requisiti elencati in precedenza.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 18/68

## Associazione e causalità

Associazione e causalità

In psicologia è difficile stabilire con certezza relazioni causali per i seguenti motivi:

- le teorie psicologiche non sono sufficientemente precise da consentire di identificare i nessi causali;
- possono esserci tante possibili cause e le teorie psicologiche non riescono ad isolare le cause corrette;
- le sequenze temporali non sono chiaramente definite.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 19/68

## Sequenza temporale

Sequenza temporale

Parte 3 – Associazione e causalità

Psicometria 2 - p. 20/68

## Sequenza temporale

Sequenza temporale

La *causa* deve precedere l'*effetto*.

- Nella ricerca sperimentale la sequenza temporale è sotto il controllo dello sperimentatore: somministrazione di un farmaco o placebo -> decorso della malattia.
- Il successo o meno del trattamento è osservato *dopo* che il trattamento viene somministrato, dunque la sequenza temporale è certa.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 21/68

## Sequenza temporale

Sequenza temporale

- Precedenza logica: l'età e il genere sono antecedenti al reddito, per esempio, e quindi devono essere considerati come cause piuttosto che come effetti.

- Nell'esempio della tavola 10.1 sullo *scouting*, S, e la delinquenza giovanile, D, sono possibili sia S -> D che D -> S.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 22/68

## Eliminazione di spiegazioni alternative

Eliminazione di spiegazioni alternative  
Evidenze aneddotiche

I requisiti dell'associazione statistica e della sequenza temporale risultano soddisfatti in molti casi in cui è assente una relazione causale.

- Vi potrebbe essere, infatti, una terza variabile Z che è al contempo causa di X e di Y, per cui se Z viene controllata, l'associazione tra X e Y scompare, ossia Y risulta statisticamente indipendente da X e la presunta relazione causale tra X e Y si rivela spuria.
- L'associazione tra due variabili può essere mediata da una terza variabile che interviene tra le due.
- L'associazione compare per errori sistematici nello studio (es. errori di campionamento).

## Eliminazione di spiegazioni alternative

Eliminazione di spiegazioni alternative  
Evidenze aneddotiche

Parte 3 – Associazione e causalità

Psicometria 2 - p. 23/68

Parte 3 – Associazione e causalità

Psicometria 2 - p. 24/68

## Evidenze aneddotiche

Le evidenze aneddotiche non sono sufficienti per provare che non vi è una relazione causale tra due variabili (es. fumo e cancro).

Eliminazione di spiegazioni alternative  
Evidenze aneddotiche

- L'associazione tra due variabili, infatti, non deve essere deterministica per essere causale.
- Per provare che non vi è relazione causale è necessario stabilire che viene violato il criterio dell'associazione statistica, o quello della sequenza temporale, o che vi sono spiegazioni alternative.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 25/68

## Controllo statistico

- Per affermare che X causa Y è necessario stabilire che l'associazione tra X e Y viene preservata quando l'influenza di altre variabili è rimossa.

Controllo statistico  
Illustrazione  
Variabile di controllo  
Illustrazione

- Si dice che una variabile è *controllata* quando la sua influenza su altre variabile viene eliminata.
- In un esperimento, una variabile può essere controllata mantenendo costante il suo valore mentre si studia la relazione tra altre variabili.
  - ◆ Es. in un esperimento di laboratorio sugli effetti di un farmaco sui ratti il ricercatore può controllare l'età o la dieta dei ratti (tutti i ratti hanno la stessa età o dieta).

Parte 3 – Associazione e causalità

Psicometria 2 - p. 27/68

## Illustrazione

- Agresti e Finlay considerano un campione di dati che contiene, tra l'altro, i punteggi di un test di abilità matematica e l'altezza degli studenti (figura 10.1).

Controllo statistico  
Illustrazione  
Variabile di controllo  
Illustrazione

- Tra abilità matematica e altezza c'è una correlazione pari a 0.81: studenti più alti hanno punteggi più alti di abilità matematica.
- L'altezza influenza l'abilità matematica, oppure ci sono delle spiegazioni alternative?

Parte 3 – Associazione e causalità

Psicometria 2 - p. 29/68

## Controllo statistico

Controllo statistico  
Illustrazione  
Variabile di controllo  
Illustrazione

- Nelle ricerche osservazionali le variabili che si vogliono controllare (es. l'intelligenza) non possono essere tenute costanti.
- Possiamo però approssimare il tipo di controllo che si ottiene negli esperimenti raggruppando insieme le osservazioni con valori simili rispetto alla variabile che si vuole controllare.
  - ◆ Es. per controllare l'effetto del grado di istruzione si possono raggruppare in gruppi gli individui che fanno parte del campione esaminato (licenza media, superiore, laurea, dottorato).
- Questa forma di controllo si dice *controllo statistico* anziché sperimentale.

Controllo statistico  
Illustrazione  
Variabile di controllo  
Illustrazione

Parte 3 – Associazione e causalità

Psicometria 2 - p. 28/68

## Illustrazione

- Una variabile che certamente influenza entrambe le variabili "altezza" e "abilità matematica" è l'età. All'aumentare dell'età entrambe queste variabili aumentano.
- Possiamo eliminare l'effetto dell'età dall'associazione tra altezza e abilità matematica controllando statisticamente questa variabile.
- Questo risultato si ottiene esaminando separatamente la relazione tra altezza e abilità matematica in gruppi d'età omogenei.

Controllo statistico  
Illustrazione  
Variabile di controllo  
Illustrazione

Parte 3 – Associazione e causalità

Psicometria 2 - p. 30/68

### Illustrazione

- Se questo viene fatto, all'interno di ciascun gruppo d'età il coefficiente di correlazione diventa prossimo a zero.

Controllo statistico  
Illustrazione  
Variabile di controllo  
Illustrazione

- L'altezza non è dunque una causa dell'abilità matematica perché l'associazione tra altezza e abilità matematica scompare quando l'età viene tenuta costante.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 31/68

### Variabile di controllo

- Mantenendo costante una *variabile di controllo* possiamo eliminare la porzione dell'associazione tra X e Y che è dovuta alla sua variazione.

Controllo statistico  
Illustrazione  
Variabile di controllo  
Illustrazione

- I grafici che rappresentano la relazione tra due variabili mantenendo costante il valore di una variabile di controllo vengono detti *parziali*.
  - ◆ Nell'esempio precedente abbiamo descritto la relazione tra due variabili quantitative (abilità matematica e altezza) nel caso in cui una terza variabile (età) è mantenuta costante.
  - ◆ E' anche possibile descrivere l'associazione tra due variabili qualitative controllando statisticamente l'effetto di una terza variabile.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 32/68

### Illustrazione

- Nella tabella 10.1 viene riportata un'ipotetica relazione bivariata tra *scouting* e comportamenti delinquenziali.

Controllo statistico  
Illustrazione  
Variabile di controllo  
Illustrazione

Comportamenti delinquenziali		
	sì	no
scout	sì 36 (.09)	364 (.91)
no	60 (.15)	340 (.85)

- Si noti che la proporzione di comportamenti delinquenziali è più alta tra coloro che non si dedicano allo scouting.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 33/68

### Illustrazione

Nella tabella seguente, la relazione tra scouting e comportamenti delinquenziali viene esaminata controllando la variabile "Partecipazione ad attività religiose".

Controllo statistico  
Illustrazione  
Variabile di controllo  
Illustrazione

		Partecipazione ad attività religiose			
		bassa	media	alta	
Delinq.		sì	no	sì	no
scout	sì	10 (.20)	40 (.80)	19 (.12)	132 (.88)
	no	40 (.20)	160 (.80)	19 (.12)	132 (.88)
				2 (.04)	48 (.96)

In ciascuna tavola parziale, la proporzione di comportamenti delinquenziali è la stessa tra scout e non scout.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 34/68

### Illustrazione

- Quando la partecipazione ad attività religiose è controllata, la relazione tra scouting e i comportamenti delinquenziali scompare.

Controllo statistico  
Illustrazione  
Variabile di controllo  
Illustrazione

- Possiamo dunque concludere che non vi è un nesso causale tra scouting e comportamenti delinquenziali.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 35/68

### Relazione spuria

Relazione spuria  
Illustrazione

Parte 3 – Associazione e causalità

Psicometria 2 - p. 36/68



### Relazione spuria

Relazione spuria  
Illustrazione

- Un'associazione tra due variabili X e Y è detta *spuria* se dipende da una terza variabile Z e scompare quando tale variabile viene controllata.
- Se l'associazione tra X e Y dipende dall'effetto di una terza variabile Z, allora non può essere interpretata come evidenza di un nesso causale tra X e Y.
  - ◆ Es. relazione spuria tra altezza e abilità matematica;
  - ◆ Es. relazione spuria tra scouting e comportamenti delinquenziali.


Parte 3 – Associazione e causalità

Psicometria 2 - p. 37/68

### Relazione spuria

Relazione spuria  
Illustrazione

Rappresentazione grafica di una relazione spuria tra X e Y. L'associazione tra X e Y scompare quando la variabile Z viene controllata.



Parte 3 – Associazione e causalità

Psicometria 2 - p. 38/68

### Relazione spuria

Relazione spuria  
Illustrazione

- In pratica, anche se la relazione tra due variabili è spuria, a causa dell'errore di campionamento, le associazioni parziali rivelate dai dati del campione non rivelano mai una completa assenza di associazione.
- Inoltre, poche relazioni sono completamente spurie. Ci può essere un qualche nesso causale tra due variabili, anche se non così forte come suggerito dall'analisi bivariata.

Relazione spuria  
Illustrazione

- Esempio 10.4: gli studenti che posseggono un computer (X) tendono ad avere punteggi (Y) più alti nei test che misurano le abilità matematiche (tavola 10.3). Possiamo concludere che il possesso di un computer faccia migliorare il rendimento nei test matematici?
  - Dobbiamo considerare la spiegazione alternativa che ipotizza l'esistenza di una terza variabile (Z) che esercita un'influenza causale su entrambe (tavola 10.4).

Parte 3 – Associazione e causalità


Psicometria 2 - p. 39/68

### Illustrazione

- La classe sociale ha un effetto sia sui punteggi di abilità matematica che sul possesso di un computer. All'aumentare della classe sociale aumenta sia la probabilità di ottenere punteggi più alti nei test matematico che la probabilità di possedere un computer.
- Questo fatto è coerente con l'esistenza di una relazione spuria tra punteggi nei test matematico e possesso di un computer.

Relazione spuria  
Illustrazione

Tale relazione spuria è rappresentata di seguito.



### Illustrazione

Parte 3 – Associazione e causalità

Psicometria 2 - p. 40/68

Parte 3 – Associazione e causalità

Psicometria 2 - p. 41/68

Parte 3 – Associazione e causalità

Psicometria 2 - p. 42/68

## Relazione a catena

Relazione a catena  
Illustrazione  
Illustrazione

- Le relazioni spurie non rappresentano l'unico caso in cui l'associazione tra X e Y scompare quando controlliamo una terza variabile Z.
- Si dicono *variabili intervenienti* quelle variabili che possono intervenire, influenzare o mascherare la relazione tra X e Y :

$$X \rightarrow Z \rightarrow Y$$

Relazione a catena  
Illustrazione  
Illustrazione

## Relazione a catena

Parte 3 – Associazione e causalità

Psicometria 2 - p. 43/68

Parte 3 – Associazione e causalità

Psicometria 2 - p. 44/68

## Relazione a catena

Relazione a catena  
Illustrazione  
Illustrazione

- Per esempio, si può osservare un'associazione tra razza e tasso di criminalità.
- Tale associazione, però, può scomparire se il reddito familiare viene controllato:  
razza -> reddito familiare      tasso di criminalità

Relazione a catena  
Illustrazione  
Illustrazione

## Relazione a catena

- Sia nel caso delle relazioni spurie che delle relazioni a catena, l'associazione tra X e Y scompare quando la variabile Z viene controllata.
- La differenza sta nell'ordine causale tra le variabili e nell'interpretazione della relazione:
  - ◆ nel caso di una associazione spuria tra X e Y, la variabile Z costituisce un antecedente causale di entrambe.
  - ◆ nel caso di una associazione a catena, la variabile Z interviene tra X e Y .

Parte 3 – Associazione e causalità

Psicometria 2 - p. 45/68

Parte 3 – Associazione e causalità

Psicometria 2 - p. 46/68

## Illustrazione

Relazione a catena  
Illustrazione  
Illustrazione

- Supponiamo che la X, livello di istruzione del padre, sia positivamente associata alla Y, il reddito del figlio all'età di quarant'anni, ma che quest'associazione scompaia se l'educazione del figlio viene controllata.
  - ◆ La correlazione tra reddito del figlio e livello di istruzione del padre è massima a zero se viene calcolata all'interno di gruppi di figli aventi un livello omogeneo di istruzione.

Relazione a catena  
Illustrazione  
Illustrazione

## Illustrazione

- In questo caso, si può pensare che il livello di istruzione del padre influenzi il livello di istruzione del figlio e, a sua volta, quest'ultimo influenzi il reddito. E' dunque naturale considerare questa situazione nei termini di un modello a catena.  
Istruzione padre -> Istruzione figlio -> Reddito
- Non ha invece senso considerare questa situazione nei termini di una relazione spuria in cui l'educazione del figlio è causalmente antecedente sia all'istruzione del padre che al reddito del figlio.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 47/68

Parte 3 – Associazione e causalità

Psicometria 2 - p. 48/68



## Cause multiple

Cause multiple

Parte 3 – Associazione e causalità

Psicometria 2 - p. 49/68

### Cause multiple

Nella rappresentazione precedente, le variabili  $X_1$  e  $X_2$  sono incorrelate.

Cause multiple

- Due variabili esplicative incorrelate potrebbero essere, per esempio, il genere e la razza.
- Se una variabile esplicativa  $X_2$  influenza la variabile  $Y$ , ma  $X_2$  è incorrelata con  $X_1$ , allora se  $X_2$  viene esclusa dall'analisi, l'associazione misurata tra  $X_1$  e  $Y$  non ne risulta distorta.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 51/68

## Variabili soppressorie

Variabili soppressorie

- Talvolta una relazione tra due variabili non risulta apparente fintanto che non viene controllato l'effetto di una terza variabile. Tale variabile si dice **variabile soppressoria** (*suppressor variable*).
- Nella tabella 10.6 sono rappresentati dei dati ipotetici in cui non vi è relazione tra reddito ed educazione.

	Reddito	
Istruzione	Alto	Basso
Alta	250	250
Bassa	250	250


Parte 3 – Associazione e causalità

Psicometria 2 - p. 53/68

## Cause multiple

Cause multiple

In psicologia, le variabili dipendenti sono solitamente influenzate da molteplici cause.




Parte 3 – Associazione e causalità

Psicometria 2 - p. 50/68

### Cause multiple

Consideriamo ora il caso in cui le variabili  $X_1$  e  $X_2$  sono associate.

Cause multiple



- In queste circostanze, se la variabile  $X_2$  viene esclusa dall'analisi, allora l'associazione misurata tra  $X_1$  e  $Y$  risulterà distorta, ovvero, non rispecchierà l'associazione che in realtà intercorre tra le due variabili.
- L'errore che si commette in tali circostanze si chiama **errore di specificazione**.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 52/68

## Variabili soppressorie

Variabili soppressorie

Parte 3 – Associazione e causalità

Psicometria 2 - p. 54/68

### Variabili soppressorie

- Nella tabella 10.5, gli stessi dati sono rappresentati in due tabelle parziali in cui viene controllata la variabile "età".

	Età bassa			Età alta			
	Reddito Alto	Basso	% Alto	Alto	Basso	% Alto	
Istruz.	Alta	125	225	35.7	125	25	83.3
	Bassa	25	125	16.7	225	125	64.3

- Se l'età viene controllata, in ciascuna tabella parziale, la percentuale di individui ad alto reddito è maggiore nel caso di un alto livello di istruzione. Il reddito, dunque, tende a crescere con il livello di istruzione.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 55/68

### Variabili soppressorie

Variabili soppressorie

- Se ignoriamo l'effetto della variabile età, però, la relazione bivarziata tra reddito e livello di istruzione scompare.

- Questo esempio suggerisce che è importante studiare le associazioni parziali anche quando le analisi bivariate rivelano assenza di associazione.

- L'esempio presente rappresenta il caso di una *assenza di relazione spuria*, in quanto sia il livello di istruzione che il reddito dipendono da una terza variabile, ovvero l'età.

Parte 3 – Associazione e causalità

Psicometria 2 - p. 56/68

### Interazione statistica

Interazione statistica  
Illustrazione  
Paradosso di Simpson

- Spesso la forza dell'associazione tra due variabili muta a seconda del valore assunto da un terza variabile.
- Se il grado di associazione tra  $Y$  e  $X_1$  assume valori diversi a seconda dei diversi livelli della variabile  $X_2$ , allora si dice che le variabili  $X_1$  e  $X_2$  *interagiscono* nel determinare il valore della variabile  $Y$ .
- L'esistenza di interazione tra variabili si può stabilire esaminando se, per i dati di un campione, la relazione tra  $Y$  e  $X_1$  rimane costante all'interno di ciascun livello di  $X_2$ .

Interazione statistica  
Illustrazione  
Paradosso di Simpson

Parte 3 – Associazione e causalità

Psicometria 2 - p. 57/68

### Illustrazione

Razza vittima	Razza accusato	Penalità di morte	Proporzione	
		sì no	sì	
Bianca	Bianca	227	4418	.049
	Nera	92	639	.126
Nera	Bianca	9	255	.034
	Nera	36	4392	.008
Totale	Bianca	236	4673	.048
	Nera	128	5031	.025

Interazione statistica  
Illustrazione  
Paradosso di Simpson

### Illustrazione

- Per questo campione (Radelet e Pierce, 1991), la pena di morte ( $Y$ ) viene inflitta più spesso agli accusati di razza bianca che a quelli di razza nera ( $X_1$ ).
- Esaminiamo però quello che succede all'interno delle tabelle parziali in cui viene controllato l'effetto della variabile "razza della vittima"  $X_2$ .

Interazione statistica  
Illustrazione  
Paradosso di Simpson

Parte 3 – Associazione e causalità

Psicometria 2 - p. 59/68

Parte 3 – Associazione e causalità

Psicometria 2 - p. 60/68

### Illustrazione

- Quando la vittima è bianca, la probabilità di ricevere la pena di morte è più alta per gli accusati di razza nera  $\pi_n = 0.126$  che per gli accusati di razza bianca  $\pi_b = 0.049$ . La differenza  $\pi_b - \pi_n = -0.077$  è negativa.

Interazione statistica  
**Illustrazione**  
Paradosso di Simpson

- Quando la vittima è nera, la probabilità di ricevere la pena di morte è più alta per gli accusati di razza bianca  $\pi_b = 0.034$  che per gli accusati di razza nera  $\pi_n = 0.008$ . La differenza  $\pi_b - \pi_n = 0.026$  è positiva.

### Illustrazione

- Dato che l'associazione tra  $X_1$  "razza dell'accusato" e  $Y$  "pena di morte" assume valori opposti a seconda del valore della variabile  $X_2$  "razza della vittima", diciamo che la variabile  $X_1$  interagisce con la variabile  $X_2$  nel determinare il valore della variabile dipendente  $Y$ .

Interazione statistica  
**Illustrazione**  
Paradosso di Simpson

- Se ci limitiamo ad interpretare i dati forniti nella tabella in cui la variabile "razza della vittima" non viene controllata, giungiamo a delle conclusioni fuorvianti (agli accusati di razza bianca viene inflitta più spesso la pena di morte).

### Illustrazione

- Tale conclusione è errata dato che una relazione di segno opposto viene rivelata quando la vittima è di razza bianca.

Interazione statistica  
**Illustrazione**  
Paradosso di Simpson


- In presenza di interazione tra variabili è necessario descrivere le associazioni presenti in ciascuna tabella parziale dato che, per diversi valori di una terza variabile, esse possono assumere segni diversi, come nel caso presente.

### Paradosso di Simpson

- Si dice *paradosso di Simpson* il caso in cui ciascuna relazione parziale assume il segno opposto rispetto alla relazione bivariata in cui non viene controllata una terza variabile.

Interazione statistica  
**Illustrazione**  
Paradosso di Simpson

- La figura seguente fornisce una rappresentazione grafica dell'interazione tra le variabili  $X_1$  e  $X_2$ .



### Conclusioni

**Conclusioni**

### Conclusioni

**Conclusioni**

- L'analisi statistica fa quasi sempre uso più di due variabili. Una relazione causale richiede
  - ◆ l'associazione statistica tra le variabili,
  - ◆ una appropriata sequenza temporale,
  - ◆ che non vi siano spiegazioni alternative.
- Spiegazioni alternative possono essere formulate nei termini di variabili di controllo che vengono mantenute costanti.

## Conclusioni

### Conclusioni

- Se la relazione tra  $Y$  e  $X_1$  viene esaminata mentre la variabile  $X_2$  viene mantenuta costante, può essere possibile stabilire che
  - ◆ la relazione tra  $Y$  e  $X_1$  è spuria:  $X_2$  influenza sia  $X_1$  che  $Y$ ;
  - ◆  $X_1$  influenza  $Y$  indirettamente tramite  $X_2$ ;
  - ◆ la relazione tra  $Y$  e  $X_1$  risulta apparente solo dopo che la variabile soppressoria  $X_2$  viene controllata;
  - ◆ il segno e la forza della relazione tra  $Y$  e  $X_1$  variano al variare di  $X_2$  (interazione).

## Conclusioni

### Conclusioni

- Nel caso di relazioni spurie e di relazioni a catena, l'associazione tra  $X$  e  $Y$  scompare se la variabile  $Z$  viene controllata.
- Nel caso in cui  $Y$  sia influenzata da cause molteplici, l'associazione tra  $Y$  e  $X_1$  può cambiare se la variabile  $X_2$  viene controllata.
- Se vi è una variabile soppressoria  $Z$ , l'associazione tra  $Y$  e  $X_1$  risulta apparente solo se  $Z$  viene controllata.
- Nel caso di un'interazione tra  $X_1$  e  $X_2$ , l'associazione tra  $X_1$  e  $Y$  può assumere intensità e direzioni diverse a seconda dei valori della variabile  $X_2$ .

## Psicomетria 1 (023-PS)

Michele Grassi  
mgrassi@units.it

Università di Trieste

Lezione 25 26

Sommario

### Sommario

Parte 4 – Modello di regressione multipla

Psicomетria 2 - p. 2/93

### Sommario

Il materiale coperto è contenuto nel capitolo 11 del testo di Agresti e Finlay (2012).

Sommario

- Modello di regressione multipla
- Due variabili esplicative
- Valori osservati, adattati e residui
- Devianza totale, spiegata, residua
- Indice di determinazione e correlazione multipla
- Condizioni di validità del modello di regressione multipla
- Correlazione parziale
- Coefficienti standardizzati

Modello di regressione multipla

### Modello di regressione multipla

Parte 4 – Modello di regressione multipla

Psicomетria 2 - p. 3/93

### Modello di regressione multipla

- Limiti della regressione semplice: la variabile dipendente, in generale, dipende da molteplici variabili indipendenti.
- La regressione multipla è un'estensione della regressione semplice in cui due o più variabili esplicative sono combinate per prevedere i valori di una variabile dipendente.

Modello di regressione multipla

Parte 4 – Modello di regressione multipla

Psicomетria 2 - p. 4/93

### Modello di regressione multipla

- La previsione dei valori  $Y$  diventa più accurata: le dimensioni dei residui diminuiscono.
- E' possibile controllare statisticamente l'effetto delle variabili confondenti:
  - ◆ Se la variabile  $X$  è associata ad altre variabili che influenzano  $Y$ , allora l'omissione di queste variabili ci porterebbe ad attribuire erroneamente il loro effetto su  $Y$  alla variabile  $X$ .

Modello di regressione multipla

Parte 4 – Modello di regressione multipla

Psicomетria 2 - p. 5/93

Parte 4 – Modello di regressione multipla

Psicomетria 2 - p. 6/93

### Una nota di cautela

Modello di regressione multipla

- La relazione tra Y e le variabili esplicative non è però necessariamente di tipo lineare.
- È quindi importante ispezionare visivamente i dati per verificare se tale ipotesi trova riscontro nei dati.

Due variabili esplicative

### Due variabili esplicative

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 7/93

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 8/93

### Due variabili esplicative

Due variabili esplicative

Vogliamo rappresentare la relazione tra il livello medio della variabile Y e due variabili esplicative  $X_1$  e  $X_2$  come una funzione

$$\hat{Y} = f(X_1, X_2)$$

o, in maniera equivalente, come

$$Y = f(X_1, X_2) + \text{residuo}$$

Due variabili esplicative

Come nel caso di un'unica variabile esplicativa, la funzione più semplice è quella lineare:

$$Y = \alpha + \underbrace{\beta_1 X_1 + \beta_2 X_2}_{\text{funzione di regressione}} + \text{residuo}$$

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 9/93

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 10/93

### Due variabili esplicative

Due variabili esplicative

- La funzione lineare


$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2$$

descrive un piano, come illustrato nella figura seguente.

- $\alpha$  è l'intercetta del piano con l'asse Y.
- $\beta_1$  è la pendenza del piano nella direzione  $X_1$  (tenendo  $X_2$  costante).
- $\beta_2$  è la pendenza del piano nella direzione  $X_2$  (tenendo  $X_1$  costante).

Due variabili esplicative

### Interpretazione geometrica



Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 11/93

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 12/93

Due variabili esplicative



### Interpretazione dei coefficienti

Due variabili esplicative

La pendenza o coefficiente angolare  $\beta_1$  esprime la variazione del valore atteso della variabile dipendente per una variazione unitaria della variabile esplicativa  $X_1$ , **se il valore di  $X_2$  viene mantenuto costante**.

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 13/93

### Interpretazione dei coefficienti

Due variabili esplicative

- Soppontiamo di sommare un'unità a  $X_1$  mentre teniamo costante il valore di  $X_2$ :

$$\begin{aligned} E(Y | X_1 + 1, X_2) &= \alpha + \beta_1(X_1 + 1) + \beta_2X_2 \\ &= \alpha + \beta_1X_1 + \beta_1 + \beta_2X_2 \end{aligned}$$

- Sottraendo da  $E(Y | X_1 + 1, X_2)$  il valore iniziale  $E(Y | X_1, X_2) = \alpha + \beta_1X_1 + \beta_2X_2$  otteniamo

$$E(Y | X_1 + 1, X_2) - E(Y | X_1, X_2) = \beta_1$$

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 14/93

### Interpretazione dei coefficienti

Due variabili esplicative

Allo stesso modo, la pendenza  $\beta_2$  può essere interpretata come il cambiamento del valore atteso della variabile dipendente per una variazione unitaria della variabile esplicativa  $X_2$ , se il valore di  $X_1$  viene mantenuto costante.

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 15/93

### Interpretazione dei coefficienti

Due variabili esplicative

- Con il **metodo dei minimi quadrati** scegliamo come stime dei parametri i valori di  $\beta_1$  e  $\beta_2$  per i quali la somma dei quadrati degli scarti delle osservazioni dalla funzione di regressione è minima.
- I calcoli necessari sono più complessi che nel caso della regressione semplice, ma le stime dei minimi quadrati  $\hat{\beta}_1$  di  $\beta_1$  e  $\hat{\beta}_2$  di  $\beta_2$  possono essere facilmente ottenute utilizzando un software.

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 16/93

### Accostamento del modello ai dati

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione multipla  
Illustrazione

### Accostamento del modello ai dati

- Dopo aver stimato il modello di regressione è opportuno verificare l'adattamento ai dati.
- L'accostamento del modello ai dati è tanto migliore quanto più elevata è la percentuale di devianza totale costituita dalla devianza spiegata.
- Di conseguenza l'adattamento può essere misurato mediante il rapporto fra la devianza spiegata e la devianza totale. Si ottiene così l'indice di determinazione  $R^2$ :

$$R^2 = \frac{\text{devianza spiegata}}{\text{devianza totale}}$$

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione multipla  
Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 17/93

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 18/93

## Indice di determinazione

L'indice di determinazione è

$$R^2 = \frac{\sum(\hat{Y}_i - \bar{Y})^2}{\sum(Y_i - \bar{Y})^2} = 1 - \frac{\sum(Y_i - \hat{Y}_i)^2}{\sum(Y_i - \bar{Y})^2}$$

dove  $\hat{Y} = \hat{\alpha} + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2$ .

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione multipla  
Illustrazione

## Coefficiente di correlazione multipla

Il **coefficiente di correlazione multipla** R è uguale al **coefficiente di correlazione di Pearson** tra i valori adattati  $\hat{Y}_i$  e i valori osservati  $Y_i$ .

- E' possibile dimostrare che il coefficiente di correlazione multipla R è uguale alla radice quadrata dell'indice di determinazione  $R^2$  ed è sempre positivo.
- L'indice di determinazione  $R^2$  (ovvero, il quadrato del coefficiente di correlazione multipla) esprime qual è la percentuale di devianza della variabile dipendente spiegata dalla relazione lineare su  $X_1$  e  $X_2$ .

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione multipla  
Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 19/93

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 20/93

## Illustrazione

**Illustrazione.** Analizziamo i dati riportati nella tabella 11.1, una piccola parte del campione raccolto da Holzer (1977).

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione multipla  
Illustrazione

## Illustrazione

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione multipla  
Illustrazione

- L'indice composito "mental impairment" è la variabile dipendente Y e misura la presenza di sintomi quali ansietà e depressione.
- La prima variabile esplicativa, "life events", misura il numero e la gravità di esperienze potenzialmente traumatiche negli ultimi tre anni (morte di una persona cara, licenziamento, traslocco, ...). Valori alti della variabile  $X_1$  indicano un numero maggiore e una maggiore severità di tali esperienze.

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 21/93

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 22/93

## Illustrazione

## Illustrazione

```
> library(sms); data(mental_impairment)
> dati<-mental_impairment
> summary(dati)
```

Y	X1	X2
Min. :17.00	Min. : 3.00	Min. : 3.00
1st Qu.:23.75	1st Qu.:32.75	1st Qu.:39.75
Median :27.00	Median :43.00	Median :56.00
Mean :27.30	Mean :44.42	Mean :56.60
3rd Qu.:31.00	3rd Qu.:55.50	3rd Qu.:75.75
Max. :41.00	Max. :97.00	Max. :97.00

```
> cor(dati)
      Y      X1      X2
Y  1.0000000  0.3722206 -0.3985676
X1  0.3722206  1.0000000  0.1233370
X2 -0.3985676  0.1233370  1.0000000
```

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 23/93


Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 24/93

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione multipla  
Illustrazione

- Possiamo utilizzare la funzione pairs di R per rappresentare graficamente i dati mediante una matrice di diagrammi di dispersione (scatterplot matrix).
- > pairs(dati)
- La prima riga della matrice riporta i grafici che pongono Y sull'ordinata e  $X_1$  e  $X_2$  sull'ascissa.
- L'ispezione visiva di questi diagrammi di dispersione suggerisce che un modello lineare rappresenta in maniera adeguata la relazione tra  $Y$ ,  $X_1$  e  $X_2$ .

### Illustrazione



Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione di correlazione multipla

#### Illustrazione


Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 25/93

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 26/93

### Illustrazione



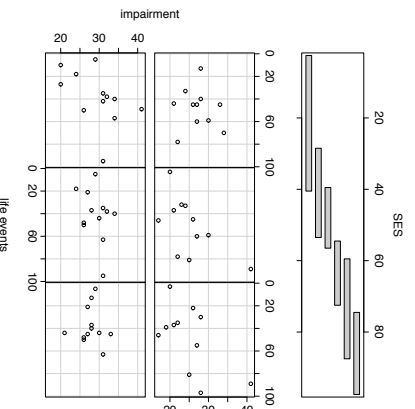
Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione di correlazione multipla

#### Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 27/93

### Illustrazione




Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione di correlazione multipla

#### Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 29/93

### Illustrazione



Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione di correlazione multipla

#### Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 26/93

### Illustrazione

- Il modello di regressione multipla  $E(Y) = \alpha + \beta_1 X_1 + \beta_2 X_2$  ipotizza che l'effetto di  $X_1$  su  $Y$  non varia a seconda del valore assunto dalla variabile  $X_2$  – lo stesso si può dire dell'effetto di  $X_2$  su  $Y$ .
- Per verificare questa ipotesi, ispezioniamo visivamente la relazione tra  $Y$  e  $X_1$  in corrispondenza di valori omogenei della variabile  $X_2$ . Una tale rappresentazione grafica può essere generata con **R** mediante la funzione `coplot`:
 

```
> coplot(Y ~ X1 | X2,
          xlab=c("life events"), ylab=c("impairment"))
```
- Non ci sono evidenze di non linearità nella relazione tra "mental impairment" e "life events".

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 28/93

### Illustrazione

- Eseguiamo innanzitutto due regressioni bivariate che descrivono come il valore atteso di  $Y$  (*mental impairment*) dipende in media da  $X_1$  (*life events*) o da  $X_2$  (*SES*).
- Le due funzioni di regressione stimate sono:

$$\hat{Y} = 23.31 + 0.090X_1$$

$$\hat{Y} = 32.17 - 0.086X_2$$

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione di correlazione multipla

#### Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 30/93

### Illustrazione

```
> fml <- lm(Y ~ X1)
> summary(fml)

Residuals:
    Min       1Q   Median       3Q      Max
-10.4415  -3.6899  -0.5973   3.6215  13.2890

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  23.30949      1.80675  12.901 1.85e-15 ***
X1           0.08983       0.03633   2.472  0.0180 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 5.133 on 38 degrees of freedom
Multiple R-Squared:  0.1385,    Adjusted R-Squared:  0.1159
F-statistic: 6.112 on 1 and 38 DF,  p-value: 0.01802
```

Parte 4 – Modello di regressione multipla Psicomетria 2 - p. 31/93

### Illustrazione

Nel primo modello di regressione,  
 $\hat{Y} = 23.31 + 0.090X_1$ , *mental impairment* è positivamente associato a *life events*.

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione  
multipla  
**Illustrazione**

- Ciò significa che, all'aumentare del numero e della gravità di eventi potenzialmente traumatici, aumenta il valore atteso della variabile che rappresenta i disturbi psicologici.

- L'indice di determinazione è  $r^2_{YX_1} = 0.14$ .

Parte 4 – Modello di regressione multipla Psicomетria 2 - p. 33/93

### Illustrazione

Esaminiamo ora la devianza spiegata e la devianza residua dei due modelli di regressione. Per il modello  $\hat{Y} = 23.31 + 0.090X_1$  abbiamo

```
> anova(fml)
Analysis of Variance Table

Response: Y
          Df Sum Sq Mean Sq F value    Pr(>F)
X1         1  161.05  161.05    6.1116 0.01802 *
Residuals 38 1001.35   26.35

---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Parte 4 – Modello di regressione multipla Psicomетria 2 - p. 35/93

### Illustrazione

```
> fm2 <- lm(Y ~ X2)
> summary(fm2)

Residuals:
    Min       1Q   Median       3Q      Max
-10.8808  -2.7472   0.2939   2.7382  15.2838

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  32.17201      1.98765  16.186 <2e-16 ***
X2          -0.08608       0.03213  -2.679  0.0109 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 5.072 on 38 degrees of freedom
Multiple R-Squared:  0.1589,    Adjusted R-Squared:  0.1367
F-statistic: 7.177 on 1 and 38 DF,  p-value: 0.01085
```

Parte 4 – Modello di regressione multipla Psicomетria 2 - p. 32/93

### Illustrazione

Nel secondo modello,  $\hat{Y} = 32.17 - 0.086X_2$ , *mental impairment* è negativamente associato a SES.

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione  
multipla  
**Illustrazione**

- Ciò significa che, all'aumentare del livello socio-economico, diminuisce il valore atteso della variabile che rappresenta i disturbi psicologici.

- L'indice di determinazione è  $r^2_{YX_2} = 0.16$ .

Parte 4 – Modello di regressione multipla Psicomетria 2 - p. 34/93

### Illustrazione

Per il modello  $\hat{Y} = 32.17 - 0.086X_2$  abbiamo

```
> anova(fm2)
Analysis of Variance Table

Response: Y
          Df Sum Sq Mean Sq F value    Pr(>F)
X2         1  184.65  184.65   7.1766 0.01085 *
Residuals 38  977.75   25.73

---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Parte 4 – Modello di regressione multipla Psicomетria 2 - p. 36/93

### Illustrazione

Consideriamo ora il modello di regressione multipla stimato

$$\hat{Y} = 28.230 + 0.103X_1 - 0.097X_2$$

```
> fm3 <- lm(Y ~ X1 + X2)
```

Coefficients:

```
Estimate Std. Error t value Pr(>|t|)
(Intercept) 28.22981    2.17422  12.984 2.38e-15 ***
X1          0.10326    0.03250   3.177 0.00300 **
X2         -0.09748    0.02908  -3.351 0.00186 **
```

```
Residual standard error: 4.556 on 37 degrees of freedom
Multiple R-Squared: 0.3392, Adjusted R-Squared: 0.3034
F-statistic: 9.495 on 2 and 37 DF, p-value: 0.0004697
```

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 37/93

### Illustrazione

- Il **coefficiente di correlazione multipla**  $R^2$  è il coefficiente di correlazione di Pearson tra i valori adattati  $\hat{Y}$  e i valori osservati  $Y$ .

```
> cor(lm3$fitted.values, Y)
[1] 0.5823736
```

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione multipla

Illustrazione

- Il quadrato del coefficiente di correlazione multipla  $R^2$  (*indice di determinazione*) rappresenta la porzione di devianza della variabile dipendente spiegata dalle variabili esplicative  $X_1$  e  $X_2$ .

```
> 0.5823736^2
[1] 0.339159
```

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 38/93

### Illustrazione

- L'associazione tra *mental impairment* e *life events* è positiva dato che  $\beta_1$  è positivo.
- Se la variabile *SES* viene controllata, l'aumento di un'unità della variabile *life events* produce un'aumento medio di 0.103 punti sulla scala *mental impairment*.

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione multipla

Illustrazione

- L'associazione tra *mental impairment* e *SES* è negativa dato che  $\beta_2$  è negativo.
- Se la variabile *life events* viene controllata, l'aumento di un'unità della variabile *SES* produce una diminuzione media di 0.097 punti sulla scala *mental impairment*.

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 39/93

### Illustrazione

- $\hat{\beta}_1 = 0.103$  e *life events* varia nella gamma (0 – 100, in questo campione 3 – 97). La variabile *life events* ha dunque un effetto sui punteggi di *mental impairment* pari a  $100 \times 0.103 = 10.3$ .

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione multipla

Illustrazione

- Dato che *mental impairment* varia nell'intervallo 17 – 41, questo effetto è considerevole.
- Le stesse considerazioni possono essere fatte a proposito di  $X_2$ .

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 41/93

### Illustrazione

Per stabilire l'entità di questi effetti, esaminiamo la gamma di valori entro cui variano i punteggi  $Y$ ,  $X_1$  e  $X_2$ :

```
> summary(dati)
      Y                X1                X2
Min.   :17.00   Min.   : 3.00   Min.   : 3.00
1st Qu.:23.75   1st Qu.:32.75   1st Qu.:39.75
Median :27.00   Median :43.00   Median :56.00
Mean   :27.30   Mean   :44.42   Mean   :56.60
3rd Qu.:31.00   3rd Qu.:55.50   3rd Qu.:75.75
Max.   :41.00   Max.   :97.00   Max.   :97.00
```

Accostamento del modello ai dati  
Indice di determinazione  
Coefficiente di correlazione multipla

Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 40/93

## Valori osservati e residui

Valori osservati e residui  
Devianza residua  
Devianza totale  
Devianza spiegata  
Indice di determinazione  
Coefficiente di correlazione multipla  
Condizioni di validità

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 42/93

## Valori osservati e residui

- Il **valore osservato** del primo soggetto è  $Y = 17$  per  $X_1 = 46$  e  $X_2 = 84$ .
- Il **valore adattato** del primo soggetto è

$$\begin{aligned}\hat{Y}_1 &= a + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2 \\ &= 28.22981 + 0.10326 \times 46 - 0.09748 \times 84 \\ &= 24.79180\end{aligned}$$

- Il **residuo** del primo soggetto è

$$\begin{aligned}E_1 &= Y_1 - \hat{Y}_1 \\ &= 17 - 24.79180 \\ &= -7.7918042\end{aligned}$$

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 43/93

Valori osservati e residui  
**Devianza residua**  
 Devianza totale  
 Devianza spiegata  
 Indice di determinazione  
 Coefficiente di correlazione  
 multipla  
 Condizioni di validità

## Devianza residua

La **devianza residua** è  $\sum(Y_i - \hat{Y}_i)^2 = \sum(E_i)^2$ .

```
> sum( residuals(fm3)^2 )
[1] 768.1616
> anova(fm3)
Analysis of Variance Table
```

```
Response: Y
Df Sum Sq Mean Sq F value Pr(>F)
X1 1 161.05 161.05 7.7572 0.008385 **
X2 1 233.19 233.19 11.2320 0.001863 **
Residuals 37 768.16 20.76
```

Valori osservati e residui  
**Devianza residua**  
 Devianza totale  
 Devianza spiegata  
 Indice di determinazione  
 Coefficiente di correlazione  
 multipla  
 Condizioni di validità

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 44/93

## Devianza totale

La **devianza totale** è  $\sum(Y_i - \bar{Y})^2$ .

```
> sum( (Y - mean(Y))^2 )
[1] 1162.4
> anova(fm3)
Analysis of Variance Table
```

Response: Y

```
Df Sum Sq Mean Sq F value Pr(>F)
X1 1 161.05 161.05 7.7572 0.008385 **
X2 1 233.19 233.19 11.2320 0.001863 **
Residuals 37 768.16 20.76
```

Valori osservati e residui  
**Devianza residua**  
**Devianza totale**  
 Devianza spiegata  
 Indice di determinazione  
 Coefficiente di correlazione  
 multipla  
 Condizioni di validità

## Devianza spiegata

La **devianza spiegata** è  $\sum(\hat{Y}_i - \bar{Y})^2$ .

```
> sum( (fitted.values(fm3) - mean(Y))^2 )
[1] 394.2384
> anova(fm3)
Analysis of Variance Table
```

Response: Y

```
Df Sum Sq Mean Sq F value Pr(>F)
X1 1 161.05 161.05 7.7572 0.008385 **
X2 1 233.19 233.19 11.2320 0.001863 **
Residuals 37 768.16 20.76
```

Valori osservati e residui  
 Devianza residua  
**Devianza spiegata**  
 Devianza totale  
 Indice di determinazione  
 Coefficiente di correlazione  
 multipla  
 Condizioni di validità

```
> 161.05 + 233.19 + 768.16
[1] 1162.4
```

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 45/93

## Indice di determinazione

Il **quadrato del coefficiente di correlazione multipla** (*indice di determinazione*) è uguale al rapporto tra la devianza spiegata e la devianza totale:

$$R^2 = \frac{\sum(\hat{Y}_i - \bar{Y})^2}{\sum(Y_i - \bar{Y})^2}$$

Per i dati dell'esempio avremo:

$$R^2 = \frac{394.24}{1162.4} = 0.3392$$

Residual standard error: 4.556 on 37 degrees of freedom  
 Multiple R-Squared: 0.3392, Adjusted R-Squared: 0.3034  
 F-statistic: 9.495 on 2 and 37 DF, p-value: 0.0004697

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 47/93

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 46/93

## Indice di determinazione

■ Dato che rappresenta la **proporzione** della devianza spiegata dal modello di regressione, l'indice di determinazione varia fra 0 e 1,

$$0 \leq R^2 \leq 1$$

■ E' pari ad 1 quando vi è un perfetto accostamento del modello ai dati. In tal caso tutte le osservazioni si trovano sul piano di regressione stimato e la devianza residua è nulla.

Valori osservati e residui  
 Devianza residua  
 Devianza spiegata  
**Indice di determinazione**  
 Coefficiente di correlazione  
 multipla  
 Condizioni di validità

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 48/93



## Indice di determinazione

- L'indice di determinazione invece è nullo quando il piano stimato è parallelo al piano definito dal  $X_1$  e  $X_2$ , cioè  $\beta_1 = \beta_2 = 0$ , e la devianza spiegata è nulla. In tal caso le variabili  $X_1$  e  $X_2$  non sono in grado di spiegare le variazioni della  $Y$ .
- $R^2$  non può diminuire se aggiungiamo una o più variabili esplicative al modello di regressione multipla. Di conseguenza,  $R^2 \hat{=} r_{YX_1}^2$  e  $r_{YX_2}^2$ .

Valori osservati e residui  
Devianza residua  
Devianza totale  
Devianza spiegata  
Indice di determinazione  
Coefficiente di correlazione multipla  
Condizioni di validità

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 49/93

## Coefficiente di correlazione multipla

- Il **coefficiente di correlazione multipla**  $R$  è uguale alla radice quadrata positiva del coefficiente di determinazione multipla:

$$R = +\sqrt{R^2}$$

```
> sqrt( 0.3392 )  
[1] 0.5824088
```

lo stesso risultato si trova calcolando la correlazione tra  $Y$  e  $\hat{Y}$ :

```
> cor(fm3$ fitted.values, y)  
[1] 0.5823736
```

Valori osservati e residui  
Devianza residua  
Devianza totale  
Devianza spiegata  
Indice di determinazione  
Coefficiente di correlazione multipla  
Condizioni di validità

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 50/93

## Condizioni di validità


- L'analisi grafica dei residui permette di stabilire se il modello di regressione è adeguato ai dati sperimentali.
- Se non esistono violazioni delle ipotesi di validità del modello ci aspettiamo che
  - ◆ la media dei residui sia uguale a zero per tutti gli intervalli di valori delle variabili esplicative,
  - ◆ la variabilità dei residui attorno allo zero sia costante per tutti i valori delle variabili esplicative.

Valori osservati e residui  
Devianza residua  
Devianza totale  
Devianza spiegata  
Indice di determinazione  
Coefficiente di correlazione multipla  
Condizioni di validità

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 51/93

## Illustrazione



Valori osservati e residui  
Devianza residua  
Devianza totale  
Devianza spiegata  
Indice di determinazione  
Coefficiente di correlazione multipla  
Condizioni di validità

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 52/93

## Più di due variabili esplicative

- Il modello di regressione multipla con  $k$  variabili esplicative  $X_1, X_2, \dots, X_k$  è

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \text{residui}$$

- Il metodo dei minimi quadrati consente di trovare i coefficienti  $\hat{\alpha}, \hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$  che minimizzano  $\sum \text{residui}_i^2$ .

Più di due variabili esplicative  
Coefficienti standardizzati  
Illustrazione

## Più di due variabili esplicative

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 53/93

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 54/93

## Più di due variabili esplicative

I coefficienti del modello di regressione multipla hanno la seguente interpretazione:

- $\alpha$  è il valore atteso della variabile  $Y$  quando  $X_1 = X_2 = \dots = X_k = 0$ ;
- $\beta_j$  è il cambiamento medio della variabile  $Y$  che accompagna un cambiamento unitario in  $X_j$ , tenendo costante il valore delle altre variabili esplicative ( $X_2, \dots, X_k$ ).
- $\beta_2, \dots, \beta_k$  hanno un'interpretazione simile.

Più di due variabili  
esplicative  
Coefficients  
standardizzati  
Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 55/93

## Coefficienti standardizzati

Spesso lo sperimentatore vuole confrontare i coefficienti del modello di regressione multipla.

- Quando le variabili esplicative sono commensurabili, il confronto è immediato.
- I coefficienti di regressione standardizzati consentono di confrontare gli effetti relativi di variabili esplicative incommensurabili.
- Per trovare i coefficienti standardizzati è necessario stimare il modello di regressione dopo avere standardizzato la variabile dipendente e le variabili esplicative.

Più di due variabili  
esplicative  
Coefficients  
standardizzati  
Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 56/93

## Più di due variabili esplicative

$$Y_i = \hat{\alpha} + \hat{\beta}_1 X_{i1} + \dots + \hat{\beta}_k X_{ik} + E_i$$

$$\bar{Y} = \alpha + \hat{\beta}_1 \bar{X}_1 + \dots + \hat{\beta}_k \bar{X}_k + E_i$$

$$Y_i - \bar{Y} = \hat{\beta}_1 (X_{i1} - \bar{X}_1) + \dots + \hat{\beta}_k (X_{ik} - \bar{X}_k) + E_i$$

$$\frac{Y_i - \bar{Y}}{s_y} = \left( \hat{\beta}_1 \frac{s_1}{s_y} \right) \frac{X_{i1} - \bar{X}_1}{s_1} + \dots + \left( \hat{\beta}_k \frac{s_k}{s_y} \right) \frac{X_{ik} - \bar{X}_k}{s_k} + \frac{E_i}{s_y}$$

$$z_{iy} = \hat{\beta}_1^* z_{i1} + \dots + \hat{\beta}_k^* z_{ik} + E_i^*$$


Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 57/93

## Illustrazione

- Analizziamo i dati della tabella 9.1 con  $Y =$  *violent crime rate*,  $X_1 =$  *poverty rate*,  $X_2 =$  *percent living in metropolitan areas* escludendo il dato relativo a Washington D.C.
- Nella prima analisi, il modello viene stimato utilizzando i dati grezzi. Nella seconda analisi, il modello viene stimato dopo avere standardizzato le variabili (si confrontino i risultati con quelli della tabella 11.11).

Più di due variabili  
esplicative  
Coefficients  
standardizzati  
Illustrazione



Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 59/93

## Più di due variabili esplicative

- $z_{iy} = (Y_i - \bar{Y})/s_y$  è la variabile dipendente standardizzata (trasformata linearmente in modo tale da avere media zero e varianza unitaria).
- $z_{1i}, \dots, z_{ki}$  sono le variabili esplicative standardizzate.
- $E^* = E/s_y$  è il residuo trasformato – non ha varianza unitaria.
- $\hat{\beta}_j^* = \hat{\beta}_j (s_j/s_y)$  è il coefficiente parziale di regressione standardizzato per la  $j$ -esima variabile esplicative.
- $\hat{\beta}_j^*$  può essere interpretato come il cambiamento medio della variabile  $Y$ , espresso nei termini della deviazione standard  $s_y$ , che risulta associato al cambiamento di una deviazione standard della variabile  $X_j$ , mantenendo costanti le altre variabili esplicative.

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 58/93

## Illustrazione

```
> ftn3 <- lm(VR ~ P + M, data=murder2)
> summary(ftn3)

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -498.683      140.988  -3.537 0.000922 ***
P             32.622       6.677   4.885 1.24e-05 ***
M             9.112       1.321   6.900 1.16e-08 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 197.9 on 47 degrees of freedom
Multiple R-Squared:  0.5708,    Adjusted R-Squared:  0.5525
F-statistic: 31.25 on 2 and 47 DF,  p-value: 2.335e-09
```

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 60/93

## Illustrazione

```
> fml4 <- lm( z.VR ~ z.P + z.M )
> summary(fml4)

Coefficients:
      Estimate Std. Error t value Pr(>|t|)
(Intercept) -9.396e-17  9.460e-02 -9.93e-16      1
z.P          4.726e-01  9.674e-02  4.885 1.24e-05 ***
z.M          6.675e-01  9.674e-02  6.900 1.16e-08 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.669 on 47 degrees of freedom
Multiple R-squared: 0.5708,    Adjusted R-squared: 0.5525
F-statistic: 31.25 on 2 and 47 DF,  p-value: 2.335e-09
```

## Una nota di cautela

- E' inappropriato usare i coefficienti standardizzati per confrontare gli effetti della stessa variabile esplicativa in campioni estratti da popolazioni con varianze diverse.
- L'uso delle deviazioni standard per standardizzare le variabili esplicative, inoltre, è inappropriato se le variabili esplicative non sono distribuite in modo normale.

Più di due variabili  
esplicative  
Coefficienti  
Standardizzati  
Illustrazione

## Interazione tra variabili

Interazione tra  
variabili  
Interazione  
statistica  
Illustrazione

- Nel modello di regressione

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ki} + E_i$$

la relazione parziale tra  $Y$  e ciascun  $X_j$  è lineare e la pendenza  $\beta_j$  che esprime tale relazione è costante per qualsiasi combinazione delle altre variabili esplicative.

- Tale modello, però, è inadeguato in presenza di **interazione statistica**.

Nel caso di variabili esplicative quantitative, si dice che esiste interazione statistica quando l'associazione tra la variabile dipendente e una variabile esplicativa cambia al mutare dei valori di altre variabili esplicative.

Interazione tra  
variabili  
Interazione  
statistica  
Illustrazione

## Termini di interazione

- Il metodo usato per rappresentare le interazioni tra variabili è quello di introdurre degli ulteriori termini di interazione nel modello di regressione multipla.

Interazione tra  
variabili  
Interazione  
statistica  
Illustrazione

- Nel caso di due variabili indipendenti, si avrà

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \beta_3 X_{i1} X_{i2} + E_i$$

- In questo modello, il termine  $X_1 X_2$  è una variabile artificiale creata facendo il prodotto delle variabili  $X_1$  e  $X_2$ .

Interazione tra  
variabili  
Interazione  
statistica  
Illustrazione

## Termini di interazione

- Se una delle due variabili esplicative, diciamo  $X_2$ , fosse qualitativa, con due livelli, allora il coefficiente  $\beta_3$  rappresenterebbe la differenza tra la pendenza della retta di regressione tra  $Y$  e  $X_1$  nei due gruppi.

- Se  $X_2$  è quantitativa, tale interpretazione può essere estesa, dicendo che  $\beta_3$  rappresenta la differenza tra la pendenza della retta di regressione tra  $Y$  e  $X_1$  tra ciascuno dei diversi valori che  $X_2$  può assumere.

## Termini di interazione

Scriviamo il modello di regressione nel modo seguente:

$$E(Y) = (\alpha + \beta_2 X_2) + (\beta_1 + \beta_3 X_2)X_1 = \alpha' + \beta_1' X_1$$

dove  $\alpha' = (\alpha + \beta_2 X_2)$  e  $\beta_1' = (\beta_1 + \beta_3 X_2)$ .

- Quando la  $X_2$  viene mantenuta costante, la media di  $Y$  cambia come funziona lineare di  $X_1$ .
- Sia l'intercetta  $\alpha'$  che la pendenza  $\beta_1'$  dipendono dal valore assunto da  $X_2$ .
- Dunque, al mutare del valore di  $X_2$ , l'effetto di  $X_1$  su  $Y$  cambia.

Interazione tra  
variabili  
Interazione  
statistica  
Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 67/93

## Termini di interazione

- Anche se nella popolazione non vi è interazione tra le variabili, per gli effetti degli errori di campionamento, nei dati del campione non succederà mai che l'effetto di  $X_1$  su  $Y$  è esattamente uguale per tutti i valori di  $X_2$  (e viceversa).
- Dobbiamo dunque sottoporre a verifica l'ipotesi nulla di assenza di interazione tra  $X_1$  e  $X_2$  nella popolazione.
- Tale ipotesi nulla viene verificata mediante un test sul coefficiente parziale di regressione  $\beta_3$  che è associato al termine di interazione  $X_1 X_2$ .

Interazione tra  
variabili  
Interazione  
statistica  
Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 69/93

## Illustrazione

**Illustrazione.** Consideriamo nuovamente l'esempio relativo alle variabili mental impairment, life events e SES e analizziamo tali dati mediante un modello che contiene il termine di interazione  $X_1 X_2$ . (tabella 11.7)

```
> fm <- lm(Y ~ X1*X2)
> summary(fm)
```

```
Coefficients:
      Estimate Std. Error t value Pr(>|t|)
(Intercept)  26.03648    3.948826   6.594 1.13e-07 ***
X1           0.155865    0.085338   1.826  0.0761 .
X2          -0.060493    0.062674  -0.965  0.3409
X1:X2       -0.000866    0.001297  -0.668  0.5087
```

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 69/93

## Illustrazione

In maniera corrispondente, se  $SE S = 50$ , la relazione stimata tra  $Y$  e  $X_1$  è

$$E(Y) = 23.012 + 0.113X_1$$

e quando  $SE S = 100$

$$E(Y) = 19.987 + 0.069X_1$$

Più alto è il valore di  $SE S$ , minore è la pendenza della retta di regressione tra life events e mental impairment. Questo indica che gli individui che possiedono maggiori risorse (valori alti di  $SE S$ ) sono meglio in grado di assorbire gli eventi potenzialmente traumatici.

Interazione tra  
variabili  
Interazione  
statistica  
Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 71/93

## Illustrazione

Se  $SE S = 0$ , la relazione stimata tra  $Y$  e  $X_1$  è

$$E(Y) = (\alpha + \beta_2 X_2) + (\beta_1 + \beta_3 X_2)X_1$$

ovvero


$$E(Y) = (26.037 + (-0.060)0) + (0.156 + (-0.00087)0)X_1$$

$$E(Y) = 26.037 + 0.156X_1$$

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 70/93

## Illustrazione



Interazione tra  
variabili  
Interazione  
statistica  
Illustrazione

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 72/93

## Illustrazione

Interazione tra  
variabili  
interazione  
statistica  
**Illustrazione**

- La discussione precedente è stata presentata solo per scopi didattici, dato che l'analisi dei dati non consente di rifiutare l'ipotesi nulla di assenza di interazione [ $t(36) = -0,668, n.s.$ ].
- Se l'ipotesi di assenza di interazione non può essere rifiutata, possiamo interpretare gli effetti principali delle variabili  $X_1$  e  $X_2$ .
- In presenza di un'interazione statisticamente significativa, invece, non ha senso interpretare gli effetti delle altre variabili. Dobbiamo invece interpretare l'effetto dell'interazione (come abbiamo fatto nell'illustrazione precedente, per esempio).

## Definizione

- Il modello di regressione multipla descrive la relazione tra due variabili, controllando l'effetto di altre variabili di interesse.

- Considereremo ora un indice che misura l'intensità dell'associazione tra due variabili, controllando l'effetto di altre variabili.

- ♦ **Illustrazione.** Per l'esempio precedente, potremmo chiederci: se la variabile *SES* viene controllata, che proporzione della varianza della variabile *mental impairment* viene spiegata dalla variabile *life events*?

- L'indice usato per rispondere a questa domanda viene chiamato **correlazione parziale**.

Correlazione  
parziale  
**Definizione**  
Illustrazione  
Calcolo di  
 $r_{Y_1 X_1 | F}$   
 $r_{X_1 X_2 | F}$   
Interpretazione di  
 $r_{Y_1 X_1 | F}$   
Partial plots

## Definizione

La correlazione parziale  $r_{Y_1 X_1 | X_2}$  non è altro che la correlazione di Pearson tra  $E_1$  e  $E_2$ , ovvero la correlazione tra le componenti di  $Y$  e  $X_1$  linearmente indipendenti da  $X_2$ .

Correlazione  
parziale  
**Definizione**  
Illustrazione  
Calcolo di  
 $r_{Y_1 X_1 | F}$   
Interpretazione di  
 $r_{Y_1 X_1 | F}$   
Partial plots

## Correlazione parziale

Correlazione  
parziale  
**Definizione**  
Illustrazione  
Calcolo di  
 $r_{Y_1 X_1 | F}$   
Interpretazione di  
 $r_{Y_1 X_1 | F}$   
Partial plots

Per calcolare la correlazione parziale tra  $Y$  e  $X_1$  al netto dell'effetto lineare di  $X_2$  è necessario trovare le componenti di  $Y$  e di  $X_1$  linearmente indipendenti da  $X_2$ .

La componente di  $Y$  linearmente indipendente da  $X_2$  è data dai residui del modello

$$Y = A_1 + B_1 X_2 + E_1$$

e lo stesso può dirsi di  $X_1$ :

$$X_1 = A_2 + B_2 X_2 + E_2$$

## Definizione

Correlazione  
parziale  
**Definizione**  
Illustrazione  
Calcolo di  
 $r_{Y_1 X_1 | F}$   
Interpretazione di  
 $r_{Y_1 X_1 | F}$   
Partial plots

## Definizione

Si ricordi infatti che, nel modello di regressione

$$Y_1 = \beta_0 + \beta_1 X_{11} + \beta_2 X_{12} + \dots + \beta_p X_{1p} + \epsilon_1$$

i coefficienti dei minimi quadrati  $\beta_0, \dots, \beta_p$  sono stati calcolati in modo tale da rendere **linearmente indipendenti** le due componenti in cui viene scomposta la  $Y_1$ :

$$\hat{Y}_1 = \beta_0 + \beta_1 X_{11} + \beta_2 X_{12} + \dots + \beta_p X_{1p}$$

- $\epsilon_1$

Correlazione  
parziale  
**Definizione**  
Illustrazione  
Calcolo di  
 $r_{Y_1 X_1 | F}$   
Interpretazione di  
 $r_{Y_1 X_1 | F}$   
Partial plots

## Illustrazione

Consideriamo nuovamente i dati della tabella 11.5 e poniamoci il problema di calcolare la correlazione parziale tra  $Y$  e  $X_1$  al netto dell'effetto di  $X_2$ .

Eseguiamo la regressione semplice di  $Y$  e di  $X_1$  su  $X_2$ :

```
> fml1 <- lm(Y ~ X2)
> fml2 <- lm(X1 ~ X2)
```

Correlazione parziale  
Definizione  
Illustrazione  
Calcolo di  $r_{Y, X_1|F}$   
Interpretazione di  $r_{Y, X_1|F}$   
Partial plots

## Illustrazione

In questo modo ciascun valore  $Y_i$  viene scomposto in due componenti indipendenti, il valore adattato  $\hat{Y}_i$  e il residuo,  $E_i$ :

```
> d <- cbind(Y, fml1$fit, fml2$res)
> d[1:4, ]
      Y
1 17 24.94146 -7.941464
2 19 23.82245 -4.822451
3 20 30.10614 -10.106141
4 20 24.85539 -4.855386
```

Lo stesso può dirsi di  $X_1$ .

Correlazione parziale  
Definizione  
Illustrazione  
Calcolo di  $r_{Y, X_1|F}$   
Interpretazione di  $r_{Y, X_1|F}$   
Partial plots

## Illustrazione

I residui  $E_{1i}$  sono incorrelati con la componente di  $Y$  predicibile da  $X_2$ :

```
> cor(fml1$fit, fml2$res)
[1] -1.982922e-17
```

I residui  $E_{2i}$ , inoltre, sono incorrelati con la componente di  $X_1$  predicibile da  $X_2$ :

```
> cor(fml2$fit, fml2$res)
[1] -1.746154e-16
```

Correlazione parziale  
Definizione  
Illustrazione  
Calcolo di  $r_{Y, X_1|F}$   
Interpretazione di  $r_{Y, X_1|F}$   
Partial plots

Correlazione parziale  
Definizione  
Illustrazione  
Calcolo di  $r_{Y, X_1|F}$   
Interpretazione di  $r_{Y, X_1|F}$   
Partial plots

## Illustrazione

Si noti come la correlazione parziale  $r_{Y, X_1|X_2}$  sia diversa della correlazione tra  $Y$  e  $X_1$ :

```
> cor(Y, X1)
[1] 0.3722206
```

La correlazione parziale può avere intensità diversa, e anche cambiare segno, rispetto alla correlazione semplice.

Correlazione parziale  
Definizione  
Illustrazione  
Calcolo di  $r_{Y, X_1|F}$   
Interpretazione di  $r_{Y, X_1|F}$   
Partial plots

## Quadrato della correlazione parziale

Il quadrato del coefficiente di correlazione parziale può essere interpretato nei termini della riduzione proporzionale dell'errore di previsione di  $Y$ .

$r_{Y, X_1|X_2}^2$  è la proporzione della varianza di  $Y$  che viene spiegata da  $X_1$ , dopo avere controllato l'effetto di  $X_2$ .

Dopo avere rimosso dalla devianza totale l'effetto di  $X_2$ ,  $r_{Y, X_1|X_2}^2$  indica la porzione della devianza rimanente che può essere attribuita alla componente di  $X_1$  linearmente indipendente da  $X_2$ .

Correlazione parziale  
Definizione  
Illustrazione  
Calcolo di  $r_{Y, X_1|F}$   
Interpretazione di  $r_{Y, X_1|F}$   
Partial plots



## Calcolo di $r_{Y, X_1|X_2}$

La correlazione parziale tra  $Y$  e  $X_1$  al netto dell'effetto di  $X_2$ ,  $r_{Y, X_1|X_2}$ , può anche essere calcolata direttamente dalle correlazioni semplici tra le tre variabili  $X_1$ ,  $X_2$  e  $Y$ :

$$\begin{aligned} r_{Y, X_1|X_2} &= \frac{r_{Y, X_1} - r_{Y, X_2}r_{X_1, X_2}}{\sqrt{(1 - r_{X_2}^2)(1 - r_{X_1, X_2}^2)}} \\ &= \frac{0.372 - (-0.399) \times 0.123}{\sqrt{(1 - 0.399^2)(1 - 0.123^2)}} = \\ &= 0.463 \end{aligned}$$

Correlazione parziale  
Definizione  
Illustrazione  
Calcolo di  $r_{Y, X_1|X_2}$   
Interpretazione di  $r_{Y, X_1|X_2}$   
Partial plots

## Interpretazione di $r_{Y, X_1|X_2}$

- Se potessimo isolare nella popolazione tutte le osservazioni che hanno un valore costante di  $X_2$ , allora la correlazione parziale  $r_{Y, X_1|X_2}$  corrisponderebbe alla correlazione di Pearson all'interno di ciascuno di questi sottogruppi.
- Come la correlazione di Pearson,  $r_{Y, X_1|X_2}$  assume valori compresi tra -1 e +1.
- La correlazione parziale  $r_{Y, X_1|X_2}$  ha lo stesso segno del coefficiente parziale di regressione  $B_1$  nell'equazione di regressione  $Y = B_0 + B_1X_1 + B_2X_2 + E$ .
- Il valore del coefficiente di correlazione parziale non dipende dall'unità di misura delle variabili.

Correlazione parziale  
Definizione  
Illustrazione  
Calcolo di  $r_{Y, X_1|X_2}$   
Interpretazione di  $r_{Y, X_1|X_2}$   
Partial plots

## Interpretazione di $r_{Y, X_1|X_2}$

- Il quadrato di  $r_{Y, X_1|X_2}$  ha un'interpretazione nei termini della riduzione proporzionale dell'errore di previsione: è la proporzione della varianza di  $Y$  che viene spiegata da  $X_1$ , dopo avere controllato l'effetto di  $X_2$  su entrambe le variabili.

Correlazione parziale  
Definizione  
Illustrazione  
Calcolo di  $r_{Y, X_1|X_2}$   
Interpretazione di  $r_{Y, X_1|X_2}$   
Partial plots

## Partial plots

```
> plot(scale(fm1$res), scale(fm2$res))
> fit <- lm(scale(fm2$res) ~ scale(fm1$res))
> abline(fit)
> summary(fit)
```

Call: `lm(formula = scale(fm2$res) ~ scale(fm1$res))`

Residuals:


Min	1Q	Median	3Q	Max
-1.699575	-0.418341	-0.009051	0.486768	2.266031

Coefficients:

Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	-2.736e-17	1.420e-01	-1.93e-16	1.00000
scale(fm1\$res)	4.630e-01	1.438e-01	3.22	0.00263 **

## Partial plots

Il coefficiente di correlazione parziale  $r_{Y, X_1|X_2}$  è uguale alla pendenza della retta di regressione tra i residui **standardizzati**  $E_1$  e  $E_2$ .



Correlazione parziale  
Definizione  
Illustrazione  
Calcolo di  $r_{Y, X_1|X_2}$   
Interpretazione di  $r_{Y, X_1|X_2}$   
Partial plots

## Conclusioni

Conclusioni

## Conclusioni

Conclusioni

- Il modello di regressione multipla che mette in relazione una variabile dipendente con un insieme di  $k$  variabili esplicative è

$$Y_i = \alpha + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \epsilon_i$$

- Il **coefficiente parziale di regressione**  $\beta_j$  rappresenta il cambiamento medio della variabile  $Y$  per un cambiamento unitario della variabile  $X_j$ , se le altre variabili esplicative sono mantenute costanti.

## Conclusioni

Conclusioni

- Il **coefficiente di correlazione multipla**  $R$  è uguale al coefficiente di correlazione di Pearson tra i valori osservati  $Y$  e i valori adattati  $\hat{Y}$ .  $R$  rappresenta dunque l'intensità della relazione lineare tra  $Y$  e le variabili esplicative.

- Il quadrato del coefficiente di correlazione multipla  $0 \leq R^2 \leq 1$  rappresenta la **riduzione proporzionale dell'errore di previsione** che si commette utilizzando  $\hat{Y} = \alpha + \beta_1 X_{i1} + \dots + \beta_k X_{ik}$  anziché anziché  $\bar{Y}$ .

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 91/93

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 92/93

## Conclusioni

Conclusioni

- I **coefficienti standardizzati**  $\hat{\beta}_j^*$  non dipendono dall'unità di misura delle variabili esplicative e descrivono il cambiamento atteso della variabile  $Y$ , espresso in termini di deviazioni standard di  $Y$ , per il cambiamento di una deviazione standard della variabile  $X_j$ , se le altre variabili esplicative sono mantenute costanti.

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 93/93

Parte 4 – Modello di regressione multipla

Psicometria 2 - p. 92/93

# Errore di specificazione, metodo dei residui e correlazione parziale: approfondimento

## Errore di specificazione

Popolazione	Campione
$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \varepsilon;$	$y = a + bx_1 + e'$
<ul style="list-style-type: none"> <li>• Supponiamo che <i>nella popolazione</i> la relazione tra <math>y</math> e le due variabili esplicative <math>x_1</math> e <math>x_2</math> sia lineare;</li> <li>• dove <math>\varepsilon</math> è incorrelato con <math>x_1</math> e <math>x_2</math>.</li> <li>• Se i dati di un campione estratto dalla popolazione vengono analizzati utilizzando entrambe le variabili <math>x_1</math> e <math>x_2</math> allora i coefficienti dei minimi quadrati forniranno delle stime non distorte (prive di errore sistematico) dei parametri <math>\beta_1</math> e <math>\beta_2</math>.</li> </ul>	<ul style="list-style-type: none"> <li>• Supponiamo però di analizzare i dati del campione con il modello di regressione bivariata, utilizzando solo <math>x_1</math>;</li> <li>• implicitamente, l'effetto di <math>x_2</math> su <math>y</math> viene assorbito nell'errore</li> </ul> $e' = e + \beta_2 x_2$ <p>e se <math>x_1</math> e <math>x_2</math> sono correlate, allora parte dell'effetto di <math>x_2</math> su <math>y</math> sarà erroneamente attribuito a <math>x_1</math>.</p>

## Errore di specificazione


## Errore di specificazione

Popolazione	Campione
$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \varepsilon;$	$y = a + bx_1 + e'$
<ul style="list-style-type: none"> <li>• Supponiamo che <i>nella popolazione</i> la relazione tra <math>y</math> e le due variabili esplicative <math>x_1</math> e <math>x_2</math> sia lineare;</li> </ul>	<ul style="list-style-type: none"> <li>• Supponiamo però di analizzare i dati del campione con il modello di regressione bivariata, utilizzando solo <math>x_1</math>;</li> </ul>
<ul style="list-style-type: none"> <li>• Vediamo di quantificare il <i>bias</i>...</li> </ul>	<ul style="list-style-type: none"> <li>• La conseguenza è che la stima dei minimi quadrati <math>b</math> sarà distorta, ossia avremo che:</li> </ul> $b = \beta_1 + bias$

Popolazione	Campione
$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + e;$	$y = a + bx_1 + e'$
<p>consideriamo il valore atteso di <math>y</math>:</p> $E(y) = \alpha + \beta_1 E(x_1) + \beta_2 E(x_2) + E(e)$	
<p>visto che <math>E(e) = 0</math>, otteniamo</p> $\mu_y = \alpha + \beta_1 \mu_1 + \beta_2 \mu_2$	

## Errore di specificazione

Popolazione



$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + e;$$

consideriamo ora la differenza  $y - \mu_y$ :

$$y - \mu_y = \cancel{\alpha} + \beta_1 x_1 + \beta_2 x_2 + e - \cancel{\alpha} + \beta_1 \mu_1 + \beta_2 \mu_2$$

dalla quale otteniamo:

$$(y - \mu_y) = \beta_1 (x_1 - \mu_1) + \beta_2 (x_2 - \mu_2) + e$$

150


Campione



$$y = a + bx_1 + e'$$

## Errore di specificazione

Popolazione



$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + e;$$

moltiplichiamo entrambi i lati per  $(x_1 - \mu_1)$ :

$$(x_1 - \mu_1)(y - \mu_y) = \beta_1 (x_1 - \mu_1)(x_1 - \mu_1) + \beta_2 (x_1 - \mu_1)(x_2 - \mu_2) + e(x_1 - \mu_1)$$

e consideriamo il valore atteso  $E[(x_1 - \mu_1)(y - \mu_y)]$ ,

$$E[(x_1 - \mu_1)(y - \mu_y)] = \beta_1 E[(x_1 - \mu_1)(x_1 - \mu_1)] + \beta_2 E[(x_1 - \mu_1)(x_2 - \mu_2)] + E[(x_1 - \mu_1)e]$$

che possiamo riscrivere come:

$$Cov(x, y) = \beta_1 Var(x_1) + \beta_2 Cov(x_1, x_2).$$

151


Campione



$$y = a + bx_1 + e'$$

## Errore di specificazione

Popolazione



$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + e;$$

risolvendo  $Cov(x, y) = \beta_1 Var(x_1) + \beta_2 Cov(x_1, x_2)$  per  $\beta_1$  otteniamo:

$$\beta_1 = \frac{Cov(x_1, y)}{Var(x_1)} - \beta_2 \frac{Cov(x_1, x_2)}{Var(x_1)};$$

dato che (come risulta dai minimi quadrati)  $\frac{Cov(x_1, y)}{Var(x_1)} = b$ ,

$$\beta_1 = b - \beta_2 \frac{Cov(x_1, x_2)}{Var(x_1)}$$

Campione



$$y = a + bx_1 + e'$$


$$b = \beta_1 + \beta_2 \frac{Cov(x_1, x_2)}{Var(x_1)}$$

$$b = \beta_1 + bias$$

152

## Errore di specificazione

Popolazione



$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + e;$$

Campione



$$y = a + bx_1 + e'$$

$$b = \beta_1 + bias$$

$$bias = \beta_2 \frac{Cov(x_1, x_2)}{Var(x_1)}$$


• L'interpretazione del bias nella stima del coefficiente di regressione bivariato dipende dalla natura della relazione tra  $x_1$  e  $x_2$ :

$bias \neq 0$  se  $x_2$   
 (a) è una variabile rilevante ( $\beta_2 \neq 0$ )  
 (b) è correlata con  $x_1$  ( $Cov(x_1, x_2) \neq 0$ )


## Errore di specificazione

Popolazione

①  $x_2$  variabile interveniente



② relazione spuria (non causale) tra  $x_1$  e  $y$



• L'interpretazione del bias nella stima del coefficiente di regressione bivariato dipende dalla natura causale della relazione tra  $x_1$  e  $x_2$

Campione

$$\left( \beta_1 + \beta_2 \frac{Cov(x_1, x_2)}{Var(x_1)} \right)$$

① il bias è l'effetto indiretto di  $x_1$  su  $y$  trasmesso attraverso  $x_2$ , dal momento che  $Cov(x_1, x_2)/Var(x_1)$  è l'inclinazione della retta di regressione di  $x_2$  su  $x_1$  nella popolazione.

②  $x_2$  è la causa comune di  $x_1$  e  $y$ ; il bias rappresenta la componente spuria dell'associazione empirica tra  $x_1$  e  $y$ .

## Correlazione parziale

Consideriamo nuovamente il modello di regressione lineare multipla:

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

e i due modelli di regressione lineare bivariata per  $X_1$




$$y = a + b_1 x_1 + e_{yx1}$$

e per  $X_2$

$$y = a + b_2 x_2 + e_{yx2}$$

155

## Correlazione parziale



La regressione multipla non corrisponde a tante regressioni bivariate. Infatti, come abbiamo visto per l'errore di specificazione, le stime degli effetti della regressione multipla sono diverse da quelle della regressione bivariata:

- per  $b_1$  avremo che (dalle regole di scomposizione della varianza - covarianza)\*

$$Cov(x_1, y) = Var(x_1)\beta_1 + \frac{Cov(x_1, x_2)}{Var(x_2)} Var(x_2)\beta_2$$




da cui

$$b_1 = \frac{Cov(x_1, y)}{Var(x_1)} = \beta_1 + \frac{Cov(x_1, x_2)}{Var(x_1)} \beta_2$$

156

\* Sewall Wright (1921, 1934)

## Correlazione parziale



La regressione multipla non corrisponde a tante regressioni bivariate.

Infatti, come abbiamo visto per l'errore di specificazione, le stime degli effetti della regressione multipla sono diverse da quelle della regressione bivariata:

- e per  $b_2$

$$Cov(x_2, y) = Var(x_2)\beta_2 + \frac{Cov(x_1, x_2)}{Var(x_1)} Var(x_1)\beta_1$$

da cui

$$b_2 = \frac{Cov(x_2, y)}{Var(x_2)} = \beta_2 + \frac{Cov(x_1, x_2)}{Var(x_2)} \beta_1$$

157

\* Sewall Wright (1921, 1934)

## Correlazione parziale

- nella regressione bivariata viene stimato l'effetto MARGINALE di X1 (o X2) su Y;
- nella regressione multipla vengono misurati gli effetti PARZIALI di ciascuna variabile indipendente (ad es. X1) AL NETTO degli effetti delle altre variabili esplicative (ad es. X2).
- I coefficienti di regressione multipla sono detti *coefficienti parziali di regressione* perché quantificano l'effetto di ciascuna variabile indipendente depurato dagli effetti attribuibili alle altre variabili inserite nel modello.
- Per chiarire il concetto di *parzializzazione* - "depurazione dagli effetti lineari delle altre variabili" - cerchiamo di eliminare il *bias* associato al coefficiente di regressione bivariato  $b_1$  che si determina quando omettiamo dal modello la *variabile rilevante & correlata* X2.

$$b_1 = \beta_1 + \underbrace{\frac{\text{Cov}(x_1, x_2)}{\text{Var}(x_1)}}_{\text{bias}} \beta_2$$

158

## Correlazione parziale

- se stimiamo l'effetto (marginale) di X1 su Y nella regressione bivariata, utilizzando però le quantità indipendenti da X2, ossia  $e_{x_1x_2}$  ed  $e_{yx_2}$ :

$$e_{yx_2} = a + b_1 e_{x_1x_2} + e$$

- (1) il coefficiente  $b_1$  coinciderà con il coefficiente parziale  $\beta_1$ , dal momento che il bias

$$\frac{\text{Cov}(x_1, x_2)}{\text{Var}(x_1)} \beta_2,$$

diventa nullo, essendo  $\text{Cov}(e_{x_1}, x_2) = 0$ , e  $\beta_2 = 0$ . (In virtù dell'utilizzo degli errori dei due modelli precedenti)

• In altre parole, ogni parametro di regressione multipla (ad es.  $\beta_1$ ) misura l'effetto parziale di una variabile AL NETTO delle altre variabili inserite nel modello. Infatti, per ottenere questo parametro nella regressione bivariata ( $b_1 = \beta_1$ ) è necessario utilizzare i punteggi delle variabili Y e X1 *depurati dall'effetto di X2*.

• Naturalmente, si tiene conto solo degli effetti delle variabili inserite nel modello, quindi gli effetti sono sempre AL LORDO di tutto ciò che non è stato considerato.

160

## Correlazione parziale

- METODO dei RESIDUI: utilizzeremo gli errori associati a due regressioni bivariate:
- la covarianza tra X1 e X2,  $\text{Cov}(x_1, x_2)$ , si può eliminare se utilizziamo la parte del punteggio di X1 linearmente indipendente da X2, ossia l'errore associato al seguente modello di regressione semplice:

$$x_1 = a + \frac{\text{Cov}(x_1, x_2)}{\text{Var}(x_2)} x_2 + e_{x_1x_2}$$

- allo stesso modo, l'effetto di X2 su Y,  $\beta_2$ , si può eliminare utilizzando la parte di punteggio di Y linearmente indipendente da X2, e quindi l'errore del modello di regressione:

$$y = a + \frac{\text{Cov}(x_2, y)}{\text{Var}(x_2)} x_2 + e_{yx_2}$$


159

## Correlazione parziale

- se stimiamo l'effetto (marginale) di X1 su Y nella regressione bivariata, utilizzando però le quantità indipendenti da X2, ossia  $e_{x_1x_2}$  ed  $e_{yx_2}$ :

$$e_{yx_2} = a + b_1 e_{x_1x_2} + e$$

- (2) la correlazione  $r$  di Pearson tra  $e_{yx_2}$  ed  $e_{x_1x_2}$  è detta correlazione PARZIALE e rappresenta la forza (e direzione) dell'associazione lineare tra Y e X1 quando l'effetto di X2 su entrambe viene eliminato.



$$pr_{x_1, y, x_2} = \frac{r_{yx_1} - r_{yx_2} r_{x_1x_2}}{\sqrt{1 - r_{yx_2}^2} \sqrt{1 - r_{x_1x_2}^2}}$$

- il concetto di correlazione parziale sarà di fondamentale importanza *nell'analisi fattoriale*.

161