

# METODI STATISTICI PER LA RICERCA SOCIALE

## CAPITOLO 14. REGRESSIONE MULTIPLA: LA SCELTA DEI MODELLI

Alessandra Mattei

Dipartimento di Statistica, Informatica, Applicazioni (DiSIA)  
Università degli Studi di Firenze  
mattei@disia.unifi.it

LM-88 SOCIOLOGIA E RICERCA SOCIALE

# Diagnostiche di regressione

- Le proprietà degli stimatori dei parametri del modello di regressione valgono se sono soddisfatte le assunzioni che sono alla base del modello
- Se una o più assunzioni sono violate si dice che il modello è **mal specificato**
- Obiettivo: Diagnostiche che permettono di stabilire se
  - ✓ Le assunzioni del modello di regressione sono violate (errata specificazione del modello)
  - ✓ Esistono osservazioni che influenzano pesantemente l'adattamento del modello e le inferenze: valori di leva (*leverage*), osservazioni *influenti*, *valori anomali/outliers*

## Il modello di regressione lineare: Assunzioni

Le osservazioni  $y_1, \dots, y_i, \dots, y_n$  sono realizzazioni di variabili aleatorie  $Y_1, \dots, Y_i, \dots, Y_n$  Normali indipendenti aventi media che è funzione lineare delle variabili esplicative  $X_1, \dots, X_K$ , e varianza costante indipendentemente dal valore delle variabili esplicative  $X_1, \dots, X_K$ :

Per  $i = 1, \dots, n$

$$Y_i | X_{i1} = x_{i1}, \dots, X_{iK} = x_{iK} \sim N(\beta_0 + \beta_1 x_{i1} + \dots + \beta_K x_{iK}, \sigma^2) \quad \text{indipendenti}$$

Quindi, per ogni  $i = 1, \dots, n$

$$\mathbb{E}(Y_i | X_{i1} = x_{i1}, \dots, X_{iK} = x_{iK}) = \beta_0 + \beta_1 x_{i1} + \dots + \beta_K x_{iK}$$

e

$$\text{Var}(Y_i | X_i = x_i) = \sigma^2 \quad \text{(ipotesi di omoschedasticità)}$$

# Il modello di regressione lineare multipla: Assunzioni


**Assunzione 1.** Per ogni unità  $i = 1, \dots, n$

$$Y_i = \beta_0 + \beta_1 \cdot x_{i1} + \beta_2 \cdot x_{i2} + \dots + \beta_k \cdot x_{ik} + \epsilon_i$$


**Assunzione 2.** Gli errori  $\epsilon_i$ ,  $i = 1, \dots, n$ , sono variabili aleatorie indipendenti aventi media nulla e varianza costante indipendentemente dal valore delle variabili esplicative  $X_1, \dots, X_K$ :

Per  $i = 1, \dots, n$       $\epsilon_i \sim N(0, \sigma^2)$      indipendenti


# Quattro data set: Anscombe (1973)




$$r_{x_1, y_1} = 0.816 \quad \hat{Y}_{i1} = 3.001 + 0.5 \cdot x_{i1}$$



$$r_{x_2, y_2} = 0.816 \quad \hat{Y}_{i2} = 3.001 + 0.5 \cdot x_{i2}$$



$$r_{x_3, y_3} = 0.816 \quad \hat{Y}_{i3} = 3.001 + 0.5 \cdot x_{i3}$$



$$r_{x_4, y_4} = 0.816 \quad \hat{Y}_{i4} = 3.001 + 0.5 \cdot x_{i4}$$




## Quattro data set: Anscombe (1973)

- La figura (a) suggerisce che il modello lineare può essere ragionevole
- La figura (b) suggerisce una relazione nonlineare
- La figura (c) mostra che i dati seguono bene il modello lineare a eccezione di un punto che si trova distante dalla retta di regressione stimata. Tale osservazione può rappresentare un valore anomalo che deve essere esaminato con attenzione
- La figura (d) suggerisce problemi nella scelta del campione o nel disegno dell'esperimento.

# Analisi dei residui

- Una tecnica che consente di investigare sulle cause di errata specificazione del modello si basa sull'analisi dei residui
- Un metodo grafico: grafico dei residui
- Il grafico dei residui è un grafico di dispersione in cui l'asse delle ordinate è riferito ai residui e l'asse delle ascisse è riferito ai valori teorici, o ai valori osservati della variabile risposta o ai valori di ciascuna variabile esplicativa
- Se il modello è ben specificato, i residui tenderanno a distribuirsi in modo casuale attorno alla retta  $\hat{\epsilon} = 0$  senza mostrare valori anomali né tendenze di fondo o comportamenti sistematici

# Il grafico dei residui in caso di corretta specificazione del modello



# Tipi di residui

- Residui di regressione

$$\hat{e}_i = y_i - \hat{y}_i = y_i - [\hat{\beta}_0 + \hat{\beta}_1 \cdot x_{i1} + \dots + \hat{\beta}_k \cdot x_{ik}]$$

- Residui standardizzati

$$\hat{e}_i^* = \frac{\hat{e}_i}{s} \quad \text{dove } s = \sqrt{\frac{\sum_i \hat{e}_i^2}{n - k - 1}}$$




- Residui studentizzati

$$\tilde{e}_i = \frac{\hat{e}_i}{\text{e.s.}(\hat{e}_i)}$$



In caso di relazione non lineare:

- I parametri del modello di regressione perdono di significato
- Le stime del valor medio per un dato valore della variabile esplicativa potrebbero risultare fortemente distorte

# Linearità



# Eteroschedasticità



# Eteroschedasticità

In presenza di eteroschedasticità





- Gli stimatori dei coefficienti di regressione e della risposta media rimangono corretti, ma perdono di efficienza;
- Le formule della varianza e dell'errore standard degli stimatori non sono più validi e il loro uso conduce ad intervalli di confidenza errati ed a verifiche di ipotesi non affidabili

Per ovviare a tali inconvenienti è necessario utilizzare stimatori dei parametri di regressione diversi dagli stimatori dei minimi quadrati standard

# Assunzione di indipendenza


- Se le osservazioni sono in una sequenza temporale, in genere gli errori non sono indipendenti
- Grafico dei residui rispetto al tempo
- I residui contigui tendono ad assumere stesso segno: **autocorrelazione positiva**
  - ✓ Sul grafico i residui mostrano comportamenti ciclici intorno allo zero
- I residui contigui tendono ad assumere segno opposto: **autocorrelazione negativa**
  - ✓ Sul grafico i residui tendono sistematicamente a cambiare segno
- In presenza di (auto-)correlazione (negativa o positiva) tra i termini di errore
  - ✓ Gli stimatori dei minimi quadrati dei coefficienti di regressione rimangono corretti ma perdono di efficienza
  - ✓ Le procedure inferenziali che ignorano l'autocorrelazione possono portare a risultati fuorvianti e errati

# Assunzione di indipendenza




# Assunzione di Normalità

## Retta di regressione




## Grafico dei residui studentizzati




# Assunzione di Normalità

Istogramma dei residui studentizzati



Q-Q plot dei residui studentizzati



## Osservazioni particolari: valori anomali

- Un valore anomalo è un'osservazione che presenta caratteristiche diverse dal resto dei dati
- Data una generica osservazione  $(x_i, y_i)$ , questa rappresenta un valore anomalo se
  - ✓ tra le unità che presentano lo stesso valore della variabile esplicativa, l'unità in esame presenta un valore della variabile risposta molto diverso
  - ✓ il valore della variabile esplicativa,  $x_i$  è *isolato* dal resto dei valori della variabile esplicativa osservati

# Osservazioni particolari

## Valori anomali (outlier) nella variabile risposta

- Osservazioni con residui standardizzati o studentizzati elevati (valori anomali della variabile risposta,  $Y$ )

## Valori di leva (leverage)

- Osservazioni con valori delle variabili esplicative distanti dalle rispettive medie (Valori anomali nelle variabile esplicative)
- Le osservazioni di leva non necessariamente presentano residui elevati

## Osservazioni Influenti

- Osservazioni con comportamento anomalo che influenzano notevolmente i risultati: Un'osservazione è influente se la sua rimozione comporta un cambiamento notevole nelle stime dei parametri e/o in  $R^2$
- Non tutti i valori anomali nella variabile risposta e i valori di leva sono necessariamente osservazioni influenti

## Valori anomali: Esempio - Abilità dei neonati

- Per 21 bambini è rilevata l'età in mesi in cui è stata pronunciata la prima parola ( $X$ ) e il punteggio ad un test di abilità ( $Y$ )
- Statistiche descrittive

$$\bar{x} = 14.381 \quad \bar{y} = 93.667$$

$$s_x^2 = 63.148 \quad s_y^2 = 195.633 \quad s_{x,y} = -71.167$$

- Modello di regressione lineare



$$Test_i = \beta_0 + \beta_1 \cdot Et\grave{a}_i + \epsilon_i$$

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 \cdot x_i = 109.874 - 1.127 \cdot x_i \quad s = 11.02 \quad e \quad R^2 = 0.41$$

$u_i$	$Età_i$	$Test_i$	$\hat{y}_i$	$\hat{e}_i$	$\hat{e}_i^*$	$\tilde{e}_i$
1	15	95	92.97	2.03	0.18	0.19
2	26	71	80.57	-9.57	-0.87	-0.94
3	10	83	98.60	-15.60	-1.42	-1.46
4	9	91	99.73	-8.73	-0.79	-0.82
5	15	102	92.97	9.03	0.82	0.84
6	20	87	87.33	-0.33	-0.03	-0.03
7	18	93	89.59	3.41	0.31	0.32
8	11	100	97.48	2.52	0.23	0.24
9	8	104	100.86	3.14	0.29	0.30
10	20	94	87.33	6.67	0.60	0.63
11	7	113	101.98	11.02	1.00	1.05
12	9	96	99.73	-3.73	-0.34	-0.35
13	10	83	98.60	-15.60	-1.42	-1.46
14	11	84	97.48	-13.48	-1.22	-1.26
15	11	102	97.48	4.52	0.41	0.42
16	10	100	98.60	1.40	0.13	0.13
17	12	105	96.35	8.65	0.78	0.81
18	42	57	62.54	-5.54	-0.50	-0.85
19	17	121	90.72	30.28	2.75	2.82
20	11	86	97.48	-11.48	-1.04	-1.07
21	10	100	98.60	1.40	0.13	0.13

## Valori anomali: Esempio - Abilità dei neonati

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 \cdot x_i = 109.874 - 1.127 \cdot x_i \quad s = 11.02 \text{ con } gdl = 19 \quad \text{e} \quad R^2 = 0.41$$



- Misura di leveraggio nella regressione lineare semplice


$$h_i = \frac{1}{n} + \frac{(x_i - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

- Nella regressione lineare multipla il calcolo dei valori  $h_i$  è più complesso
- Media dei valori  $h_i$ :  $(k + 1)/n$ 
  - ✓ Nella regressione lineare semplice:  $(k + 1)/n = 2/n$
- Valori di  $h_i$  maggiori di  $2 \cdot (k + 1)/n$  indicano valori di leva molto elevati


# Punti di leva: Esempio - Abilità dei neonati

Media dei valori  $h_i$  :  $\frac{2}{21} = 0.095 \implies 2 \cdot \text{Media dei valori } h_i = 0.19$

Dot-plot dei valori  $h_i$



Box-plot dei valori  $h_i$





# Cosa fare in presenza di valori anomali

- La presenza di valori anomali può avere degli effetti rilevanti sulla regressione alterando i risultati dell'analisi.
- Gli effetti della presenza di valori anomali possono essere analizzati confrontando il modello stimato su tutti i dati con il modello stimato eliminando preliminarmente i dati che si sospetta essere anomali
- L'effetto di disturbo sulla regressione dovuto alla presenza di valori anomali potrebbe essere neutralizzato eliminando i valori anomali.
- Prima di eliminare i valori anomali è importante comprendere la ragione della loro anomalia
- In assenza di errori di rilevazione, la presenza di valori anomali indica che il modello non è in grado di prevedere adeguatamente tutti i dati

## Valori anomali: Esempio - Abilità dei neonati

Eliminando l'osservazione  $u_{19} = (17, 121) \dots$



$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 \cdot x_i = 109.305 - 1.193 \cdot x_i \quad s = 8.628 \text{ con } gdl = 18 \quad e \quad R^2 = 0.5716$$



# Valori anomali: Esempio - Abilità dei neonati

Eliminando l'osservazione  $u_{18} = (42, 57) \dots$



$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 \cdot x_i = 105.630 - 0.779 \cdot x_i \quad s = 11.11 \text{ con } gdl = 18 \quad e \quad R^2 = 0.1122$$




## Valori anomali: Esempio - Abilità dei neonati

Eliminando le osservazioni  $u_{18} = (42, 57)$  e  $u_{19} = (17, 121) \dots$

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 \cdot x_i = 107.586 - 1.05 \cdot x_i \quad s = 8.831 \text{ con } gdl = 17 \quad e \quad R^2 = 0.2701$$



## Valori anomali: Esempio - Abilità dei neonati



—  $n = 21$ : Tutte le osservazioni

—  $n = 20$ : Eliminata l'osservazione  $u_{18} = (42, 57)$

—  $n = 20$ : Eliminata l'osservazione  $u_{19} = (17, 121)$

—  $n = 20$ : Eliminata le osservazioni  $u_{18} = (42, 57)$  e  $u_{19} = (17, 121)$

# Multicollinearità

- Esiste **multicollinearità** in presenza di variabili esplicative tra loro molto correlate
  - ✓ Una variabile è collineare con le altre se l'indice  $R^2$  di un modello di regressione che pone tale variabile in funzione di tutte le altre variabili esplicative è elevato
- L'effetto principale dovuto alla multicollinearità è quello di aumentare considerevolmente la varianza degli stimatori dei minimi quadrati dei coefficienti di regressione.
- L'aumento della varianza dovuto alla multicollinearità ha degli effetti negativi sull'inferenza dei coefficienti di regressione.
  - ✓ L'incremento dell'errore standard degli stimatori dei coefficienti porta all'aumento dell'ampiezza dell'intervallo di confidenza
  - ✓ L'aumento dell'errore standard fa diminuire il valore assoluto della statistica test portando più facilmente a non rifiutare l'ipotesi nulla anche se questa non è vera, ossia a commettere con maggiore probabilità un errore del secondo tipo.

# VIF: Variance Inflation Factor

- Variance inflation factor (fattore di inflazione della varianza): indice utilizzato per misurare il livello di multicollinearità di una variabile esplicativa  $X_j$  con le altre

$$VIF_j = \frac{1}{1 - R_j^2}$$

dove  $R_j^2$  è il coefficiente di determinazione lineare del modello di regressione nel quale la variabile  $X_j$  dipende dalle altre variabili esplicative

- ✓ Il valore minimo del  $VIF_j$  è 1 e indica che la variabile  $X_j$  è incorrelata dalle altre
- ✓ In genere, un valore superiore a 2 indica un livello sufficientemente alto di multicollinearità

## Multicollinearità: Esempio - Numero di crimini

- Dati relativi a 141 aree metropolitane degli Stati Uniti nel 1977

$Y$  = Numero di crimini

$X_1$  = Popolazione (in migliaia)

$X_2$  = % di popolazione con 65 anni e più

$X_3$  = % di popolazione con diploma superiore

$X_4$  = Forza lavoro (in migliaia)

- Modello di regressione lineare

$$Y_i = \beta_0 + \beta_1 \cdot X_{i1} + \beta_2 \cdot X_{i2} + \beta_3 \cdot X_{i3} + \beta_4 \cdot X_{i4} + \epsilon_i$$

Variabile	Coefficiente	E.S
Costante	-29059.26	13902.84
Popolazione (migliaia)	76.44	17.61
% popolazione di 65 anni e più	168.18	208.30
% con diploma superiore	388.49	653.44
Forza lavoro (migliaia)	-22.20	38.40

# Multicollinearità: Esempio - Numero di crimini

- VIF

Variabile	$R_j^2$	VIF
Popolazione (migliaia)	0.995	205.956
% popolazione di 65 anni e più	0.08	1.087
% con diploma superiore	0.081	1.089
Forza lavoro (migliaia)	0.995	206.150

- la variabile Popolazione e Forza Lavoro presentano un valore molto elevato del VIF indicando presenza di multicollinearità

## Multicollinearità: Esempio - Numero di crimini

- Se una variabile esplicativa è inserita nel modello soprattutto per ragioni di controllo (ma non è di diretto interesse il suo effetto sulla variabile risposta) non è importante considerare problemi di multicollinearità
- Fattori che possono suggerire la presenza di problemi potenzialmente dovuti a multicollinearità:
  - ✓ Radicali cambiamenti nella stima di un coefficiente quando un'altra variabile esplicativa è inclusa nel modello
  - ✓ Test  $F$  per il confronto del modello con il modello nullo suggerisce di rifiutare l'ipotesi nulla ma nessun coefficiente parziale è statisticamente significativo singolarmente preso
- L'interpretazione del coefficiente perde di senso in presenza di multicollinearità

# Multicollinearità: Osservazioni

- Alcuni approcci per rimediare alla multicollinearità
  - ✓ Scegliere un sottoinsieme di variabili esplicative, rimuovendo le variabili che spiegano solo una piccola parte della variabilità residua
  - ✓ Se diverse variabili esplicative sono altamente correlate e si riferiscono tutte a una stessa caratteristica sottostante, è possibile costruire un indice riassuntivo combinando i valori di tali variabili
- La multicollinearità non influisce sull'analisi degli effetti congiunti delle variabili esplicative: la multicollinearità non altera la bontà di adattamento del modello e la sua capacità previsiva rispetto alla variabile risposta.