

Lezione 8

La regressione multipla:
Modello statistico e assunzioni

Argomenti della lezione:

- Il modello teorico
- Il calcolo dei parametri
- Assunzioni e verifica

Nella regressione multipla abbiamo una variabile dipendente che regredisce su almeno due variabili indipendenti

Equazione di regressione:

$$Y' = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n$$


$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon_i$$

Piano di regressione (per due VI) o iperpiano (per più di 2 VI)

Equazione del piano di regressione:

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

Il piano di regressione



Coefficienti di regressione multipla: coefficienti "parziali"

Per ogni VI rappresentano:

- ➔ l'influenza della VI sulla VD, al netto delle altre VI

**Nell'equazione di regressione
multipla $Y' = \alpha + \beta_1 X_1 + \beta_2 X_2$:**

- ↻ β_1 rappresenta l'inclinazione della
retta di regressione di Y su X_1
quando si mantiene costante X_2
- ↻ β_2 rappresenta l'inclinazione della
retta di regressione di Y su X_2
quando si mantiene costante X_1

**Stime dei coefficienti:
minimi quadrati multipli**

$$\Sigma[Y - (\alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k)]^2 = \min$$

Individuare un iperpiano
di dimensioni k che si adatti meglio
ai punti dispersi in uno spazio di
dimensioni k+1 (k VI e 1 VD)

Espressioni matriciali:

equazione di regressione

$$y = bX + e$$

coefficienti di regressione

$$b = (X'X)^{-1} X'Y$$

residui

$$e = Y - (Xb + a)$$


**Misure di associazione
tra VI e VD**

Consideriamo:


2 VI: X_1 e X_2



1 VD: Y

$a+c =$ varianza
in comune tra X_1 e Y



$c+b =$ varianza
in comune tra X_2 e Y





Correlazione Semi - parziale:

$$sr_{y1.2} = \frac{r_{y1} - r_{y2} r_{12}}{\sqrt{1 - r_{12}^2}}$$

Correlazione tra X₁ e Y, quando X₂ viene parzializzata solo da X₁

$$sr^2_{y1.2} = a/(a+c+b+e)$$

proporzione della varianza totale di Y spiegata unicamente da X₁ al netto di X₂

Correlazione Parziale:

$$pr_{y1.2} = \frac{r_{y1} - r_{y2} r_{12}}{\sqrt{(1 - r_{y2}^2)(1 - r_{12}^2)}}$$

Correlazione tra X₁ e Y, quando X₂ viene parzializzata da Y e da X₁

$$pr^2_{y1.2} = a/(a+e)$$

proporzione della varianza di Y non spiegata da X₂, spiegata unicamente da X₁ al netto di X₂

Coefficiente di regressione:

$$b_{y1.2} = \frac{b_{y1} - b_{y2} b_{12}}{1 - r_{12}^2}$$

$$\beta_{y1.2}^{\wedge} = b_{y1.2} \frac{s_1}{s_y} = \frac{r_{y1} - r_{y2} r_{12}}{1 - r_{12}^2}$$

Cambiamento atteso in Y in seguito ad un cambiamento di una unità (b) o di una deviazione standard (β[^]) in X₁ al netto di X₂

Varianza spiegata

- ➔ **Coefficiente di correlazione multiplo (R o RM):** associazione tra una VD e un insieme di VI
- ➔ **Coefficiente di determinazione multiplo (R²):** proporzione di varianza della VD spiegata dalle VI prese nel loro complesso

$$R_{y.12\dots k}^2 = \sum r_{yi} \beta_{yi}^{\wedge}$$

nel caso di due VI la formula è:

$$R_{y.12}^2 = r_{y1} \beta_{y1}^{\wedge} + r_{y2} \beta_{y2}^{\wedge}$$

Somma dei prodotti delle correlazioni semplici e dei coefficienti β^{\wedge} tra la VD e ogni VI

Il coefficiente di correlazione multiplo si ottiene da R^2 :

$$R_{y.12\dots k} = \sqrt{R_{y.12\dots k}^2}$$

Coefficiente di determinazione multiplo corretto (Adjusted)

$$AR^2 = R^2 - (1-R^2) \cdot (k / (N-k-1))$$

Significatività statistica del coefficiente di determinazione (R^2)

Ipotesi statistiche:

$H_0: \rho = 0;$
(equivale a $H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$)

$H_1: \rho > 0$

Varianza	Somme dei Quadrati	GDL	Stime della Varianza
Totale	Σy^2	N-1	
Spiegata	$R^2 \Sigma y^2$	K	$R^2 \Sigma y^2 / k$
Non Sp.	$(1-R^2) \Sigma y^2$	N-k-1	$(1-R^2) \Sigma y^2 / (N-k-1)$

$$F = R^2(N-k-1) / ((1-R^2)k)$$

Significatività statistica della differenza dei singoli b da 0

$H_0: \beta = 0; H_1: \beta \neq 0 (<, >)$

Test appropriato su dati campionari:

$$t = (b - 0) / S_b$$

con N-k-1 gradi di libertà

S_{bi} è la stima campionaria dell'errore standard di β definita come:

$$S_{bi} = \frac{S_y}{S_i} \sqrt{\frac{1-R_y^2}{N-k-1}} \sqrt{\frac{1}{1-R_i^2}}$$

Errore standard della stima ed errore standard dei parametri

$$S_e = \sqrt{\frac{\sum(Y-Y')^2}{N - k - 1}}$$

$$S_{bi} = \sqrt{\frac{S_e^2}{\sum(X - \bar{X})^2 (1 - R_i^2)}}$$

Assunzioni alla base della regressione multipla

→ **Assenza errore di specificazione**

- ☞ Relazione tra le X_i e Y : lineare
- ☞ Non sono state omesse variabili indipendenti rilevanti
- ☞ Non sono state incluse variabili indipendenti irrilevanti

→ **Assenza di errore di misurazione: X_i e Y misurate senza errore**

- **Le VI sono quantitative o dicotomiche, la VD è quantitativa**
- **Le varianze sono > 0**
- **Il campionamento è casuale**
- **Assenza di multicollinearità**

→ **Assunzioni sui residui**

- ☞ **Media uguale a zero: $E(e_i) = 0$**
- ☞ **Omoschedasticità, $VAR(e_i) = \sigma^2$**
- ☞ **Assenza di autocorrelazione: $Cov(e_i, e_j) = 0$**
- ☞ **Non correlazione tra VI e residui: $Cov(e_i, X_i) = 0$**
- ☞ **Normalità**

Violazione delle assunzioni

Esame della distribuzione dei residui $e = (Y - Y')$ rispetto ai punteggi teorici Y'

Utile per rilevare:

- **La non linearità**
- **La non omogeneità della varianza**
- **La non normalità dei residui**

Violazione delle assunzioni

**La Multicollinearità
(correlazione elevata tra i predittori)
può essere rilevata:**

- dalle correlazioni tra le VI (>.8)
- da R^2 elevati e β bassi
- da errori standard elevati
- dagli indici di tolleranza e VIF

Indice di tolleranza:
quantità di varianza di una variabile
indipendente non spiegata dalle
altre variabili indipendenti

$$T_i = (1 - R_i^2)$$

dove R_i^2 è il coefficiente di
determinazione nella regressione
della variabile indipendente i sulle
altre variabili indipendenti

Il Variance Inflation Factor (VIF)

costituisce il reciproco
dell'indice di tolleranza

$$VIF_i = 1/T_i = 1/(1 - R_i^2)$$

Valori bassi \Rightarrow bassa collinearità
valori alti \Rightarrow elevata collinearità

**Non indipendenza degli errori
(Autocorrelazione), rilevata tramite:**

- l'esame dei residui ($Y - Y'$)
rispetto all'ordine
di acquisizione dei dati
- il Test di Durbin-Watson

Test di Durbin-Watson:
ha un valore compreso tra 0 e 4


Se $n > 100$ e le VI sono almeno 2:

Valori tra 1.5 e 2.2 \Rightarrow
assenza di autocorrelazione

Valori $< 1.5 \Rightarrow$ autocorr. positiva
Valori $> 2.2 \Rightarrow$ autocorr. negativa

**Esame della
distribuzione dei
residui:**


Alcuni esempi



0


Assunzioni rispettate

**Punteggi predetti Y' : in ascisse
Residui $(Y-Y')$: in ordinate**




0

**Punteggi predetti Y' : in ascisse
Residui $(Y-Y')$: in ordinate**



0


**Punteggi predetti Y' : in ascisse
Residui $(Y-Y')$: in ordinate**



0


Eteroschedasticità

**Punteggi predetti Y' : in ascisse
Residui $(Y-Y')$: in ordinate**



0

**Punteggi predetti Y' : in ascisse
Residui $(Y-Y')$: in ordinate**



0

Autocorrelazione

**Tempo o ordine di acquisizione: in ascisse
Residui $(Y-Y')$: in ordinate**

CONCLUSIONE

- **Minimi quadrati multipli**
- **Coefficienti parziali**
- **Verifica di ipotesi**
- **Assunzioni e loro verifica**