

## LEZIONE N. 11 ( a cura di MADDALENA BEI)

F- test

Assumiamo l'ipotesi nulla

$$H_0: \beta_1, \dots, \beta_k = 0$$

E' diverso dal verificare che  $H_0: \beta_j = 0$

In realtà F - test è più generale

$$H_0: A\beta = 0$$

$$H_1: A\beta \neq 0$$

A è una matrice di dimensioni opportune che si chiama matrice dei vincoli

$$\text{Prendiamo } A = (0, \dots, 1, 0, \dots, 0)$$

Se facciamo  $A\beta = \beta_2$  viene fuori un solo valore; quindi il caso più semplice è considerando A come vettore riga in cui tutti gli elementi sono uguali a zero tranne uno, uguale a 1. Se 1 è nella terza posizione otterremo  $\beta_2$  perché prima vi è l'intercetta.



$$(0, 0, 1, 0) = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \end{pmatrix} = \beta_2$$

Ovviamente possiamo esprimere anche forme più complesse. Potrei avere:

k=3

$$A = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$

$$A\beta = \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix}$$

$H_0: \beta_1, \beta_2 = 0 \iff$  Non va verificata con t bensì con F - Fisher e col caso generale

Posso dire che alcuni coefficienti sono congiuntamente uguali a zero

Ipotesi:

k=3

$$A = \begin{pmatrix} 0 & 1 & -1 & 0 \end{pmatrix}$$

$$A\beta = (\beta_2 - \beta_1)$$



Qui in corrispondenza ho 1

$$H_0: \beta_1 = \beta_2$$

Avremo che il coefficiente della prima covariata è uguale al coefficiente della seconda covariata

$$H_0: A\beta = 0$$

- 1) Singolo parametro quindi  $(r(A) = 1)$
- 2) Blocco di parametri  $(r(A) > 1)$
- 3)  $\iff$  Contrasto  $(r(A) = 1)$  nella stessa riga ho il vettore i cui valori sommano zero (tipicamente ho una riga)

Come si fa a verificare  $H_0$ ?

- 1) Si stima il modello senza vincolo (MODELLO SVINCOLATO) con tutte le covariate e memorizzo la  $DR_1$  (devianza residua). Il modello è così espresso:

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

- 2) Si stima il modello con il vincolo (MODELLO VINCOLATO) che è l'ipotesi nulla  $H_0$ .
- $$Y_i = \beta_0 + \beta_3 X_{i3} + \epsilon_i \quad (\text{se riguarda il secondo caso})$$

Una volta stimata ottengo  $DR_0$ .

A questo punto posso calcolare la statistica F

$$F_{oss} = \frac{(DR_0 - DR_1)r(A)}{DR_1 / (n - (k+1))}$$

$\downarrow$   
 $S^2$  svincolato

$F_{oss} = F_{osservato}$

Ci dice quanto è l'errore senza covariate.

Ipotesizzo un modello pieno

Modello vincolato ha  $DR_0 > DR_1$  dove  $DR_1$  rappresenta il modello svincolato

Va ricordato che :

$DR$  = misura l'errore di previsione del modello

$r(A)$  = dimensione di A uguale al numero dei vincoli

Stimo il modello con e senza ipotesi e ricapitolando avremo che il modello svincolato usa tutte le covariate, il vincolato né toglie alcune con effetto sulla DR che sarà più piccola

Vediamo come la F ha distribuzione

$F \sim F(r(A), n - (k+1))$  sotto  $H_0$

Se è vera avrà valori abbastanza piccoli

$SE F \geq F_\alpha \implies$  Allora si rifiuta  $H_0$  ( $RH_0$ )  $\implies$  Allora almeno la prima o seconda covariata è utile per vedere la reale influenza di y

Anche qui posso calcolare il p - value =  $p(F \geq F_{oss})$

Allora posso verificare diverse teorie:

$H_0: A\beta = 0$

$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$  che dice che nessuna covariata è utile per spiegare la y

Pongo

$$A = \begin{pmatrix} 0 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{pmatrix}_{k \times (k+1)}$$

Per verificare le ipotesi

1) Stimare modello svincolato  $DR_1$

2) Stimare modello vincolato ( $H_0$ ) che è  $Y_i = \beta_0 + \epsilon_i \implies \beta_0 = \bar{Y} \implies DR_0 = \sum_i (Y_i - \hat{Y}_i)^2 = \sum_i (Y_i - \bar{Y})^2 = \text{Dev}(Y)$

Rimane solo  $\beta_0$  gli sono tutti uguali a zero

Il modello diventa semplice. DR è UGUALE ALLA Dev (Y) cioè il valore previsto per ogni soggetto è uguale alla Y

$$Foss = \frac{(DR_0 - DR_1)r(A)}{DR_1 / (n - (k+1))}$$

$$DR_0 = Dev(Y)$$

$$Foss = \frac{(Dev(Y) - DR_1)/k}{DR_1 / (n - (k+1))} = \frac{DS/k}{DR_1 / (n - (k+1))}$$

Questo è come verificare  $H_0 : A\beta = 0$

Quindi abbiamo tre diverse ipotesi:

- un singolo coefficiente uguale a zero ;
- un blocco di coefficienti uguali a zero;
- due coefficienti uguali tra loro

Fin' ora abbiamo scritto il modello con le covariate in x e ci aspettiamo che siano variabili quantitative. Nella pratica ci interessa inserire il modello con covariate qualitative nel modello della regressione multipla

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

Y= reddito ( variabile risposta)

X<sub>1</sub> = anni di istruzione ( prima covariata)

X<sub>2</sub> = sesso ( seconda covariata)

Inserisco variabili dummy ( sono sempre uguale a 0 o ad 1 e permettono di introdurre una variabile qualitativa). Creo:

$$Z_2 = \begin{cases} 0 & \text{se } X_2 = M \\ 1 & \text{se } X_2 = F \end{cases}$$

Posso riscrivere il modello come

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 Z_{i2} + \epsilon_i$$

Otengo tre coefficienti:

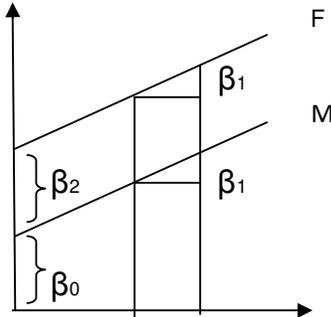
- $\beta_0 = E(Y_i) \text{ se } X_{i1} = 0 \text{ } Z_{i2} = 0$   
 $\beta_0$  è il reddito di un maschio con  $x_1 = 0$ , è il valore atteso se tutte le covariate sono uguali a 0. In particolare qui se  $\beta_0 = 20$  significa che un maschio a 18 anni ha un reddito atteso di 20.000 euro.
- $\beta_1 = E(Y_i | X_{i1} = x+1) - E(Y_i | X_{i1} = x)$   
 $\beta_1$  è l'incremento del reddito atteso se la x cresce di 1. All'aumentare di x,  $\beta_1$  cresce sia per i maschi che per le femmine.  $\beta_1 = 2$
- $\beta_2 = E(Y_i | F) - E(Y_i | M)$   
 Se calcolo il reddito per una femmina avremo :  
 $\beta_0 + \beta_1 X_{i1} + \beta_2 - (\beta_0 + \beta_1 X_{i1})$   
 $\beta_2$  è la differenza nel reddito atteso fra femmine e maschi a parità di età. Se  $\beta_2 = 2$  a parità di condizioni una donna guadagna più di un uomo.

$$M: \beta_0 + \beta_1 X_{i1} + \epsilon_i$$

$$F: \beta_0 + \beta_1 X_{i1} + \beta_2 + \epsilon_i = (\beta_0 + \beta_2) + \beta_1 X_{i1} + \beta_2 + \epsilon_i$$



Cambia solo l'intercetta.



$\beta_0$  è il reddito di un maschio ;  $\beta_1$  comprende sia i maschi che le femmine ;  $\beta_2$  è la differenza tra le due rette.

L'introduzione di dummy permette di prendere in considerazione:

- 1) la variabile qualitativa
- 2)  $\beta_2$
- 3) Due rette parallele

Come si verifica dando al modello  $\beta_2 = 0$ , cioè non consideriamo l'effetto sesso.

$H_0: \beta_2 = 0$  lo possiamo fare con t-stat

Quando abbiamo le rette parallele significa che l'incremento della covariata ha lo stesso effetto su Y (reddito).

L'ipotesi più attendibile è che il reddito cresca in modo diverso.

Possiamo scrivere:

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



TERMINE DI INTERAZIONE ( inferenza fra le due covariate)

Diventa:

$$M: Y_i = \beta_0 + \beta_1 X_{i1} + \epsilon_i \quad Z_{i2} = 0$$

$$F: Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 + \beta_3 X_{i1} + \epsilon_i$$

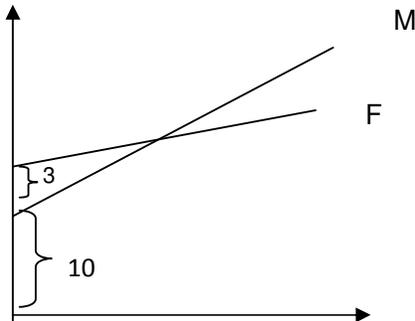
$$(\beta_0 + \beta_2) + (\beta_1 + \beta_3) X_{i1} + \epsilon_i$$

(Ho creato una sola intercetta)

E' indispensabile scriverlo così per fare una stima.

- $\beta_0 = 10$  è il reddito atteso per un maschio a 18 anni
- $\beta_1 = 2$  è l' incremento di reddito di un maschio quando l'età aumenta di uno
- $\beta_2 = 3$  è la differenza fra reddito delle femmine e dei maschi a 18 anni ; è l'intercetta

- $\beta_3 = -1$  è la differenza fra femmine e maschi nell'incremento del reddito quando aumenta un anno di età. E' la differenza nel ritmo di crescita e coincide col coefficiente angolare



Se vogliamo verificare che non c'è differenza fra i maschi e le femmine dobbiamo porre

$$H_0 = \beta_2 = \beta_3 = 0$$

Dobbiamo usare la F-test (ipotesi su più parametri)

$$r(A)=2$$

Caso della variabile qualitativa con più livelli

Prendiamo  $X_2$  con  $c$  categorie allora devo introdurre  $\rightarrow c-1$  variabili dummy

Precisiamo che il sesso ha due categorie

$X_2 =$  titolo di studio { Licenza media  
Superiore  
Laurea triennale  
Laurea quinquennale

In questo caso ho  $c=4$  quindi  
3 variabili dummy

$z_2 =$  { 0 altrimenti  
1 superiore

$z_3 =$  { 0 altrimenti  
1 laurea triennale

$z_4 =$  { 0 altrimenti  
1 laurea quinquennale

Dobbiamo escludere la prima (la licenza media in quanto non c'è bisogno di inserirla).

Per ogni titolo di studio ho una certa configurazione di dummy

	$z_2$	$z_3$	$z_4$
Media	0	0	0

Superiore	1	0	0
Laurea 3	0	1	0
Laurea 5	0	0	1

Ora si tratta di scrivere il modello di regressione lineare in una equazione che sia stimabile.

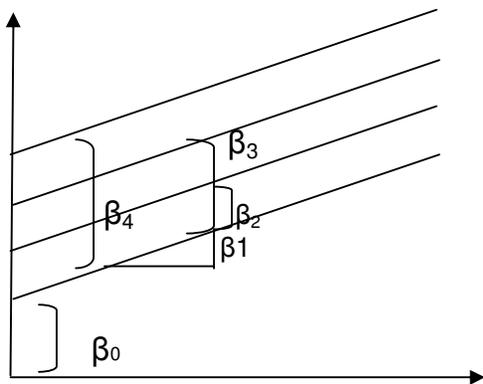
$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 Z_{i2} + \beta_3 Z_{i3} + \beta_4 Z_{i4} + \epsilon_i$$

Bisogna capire come diventa l'equazione:

media	$Y_i = \beta_0 + \beta_1 X_{i1} + \epsilon_i$
Superiore	$Y_i = (\beta_0 + \beta_2) + \beta_1 X_{i1} + \epsilon_i$
Laurea triennale	$Y_i = (\beta_0 + \beta_3) + \beta_1 X_{i1} + \epsilon_i$
laurea quinquennale	$Y_i = (\beta_0 + \beta_4) + \beta_1 X_{i1} + \epsilon_i$

Le medie sono la categoria di riferimento; tutte le dummy sono uguali a zero; tutti i coefficienti che aggiungo li confronto con le dummy

Caso in cui le rette sono parallele:



Se ipotizzo che non c'è effetto sul titolo di studio

$$H_0: \beta_2 = \beta_3 = \beta_4 = 0 \quad (\text{TEST F con la matrice di contrasto})$$

$H_0: \beta_3 = \beta_4$  implica che non c'è differenza fra laurea triennale e quinquennale e quindi le due rette coincidono

Lo posso formulare con  $A = (0 \ 0 \ 0 \ -1 \ 1)$