

Stimatore vincolato e test F per  $H_0: R'\beta - r = 0$

$$y = X\beta + \varepsilon, \quad \varepsilon|X \sim \begin{pmatrix} 0 \\ \sigma^2 I_m \end{pmatrix} \quad \text{rank}(X) = k < m$$

$n \times 1$     $n \times k$     $n \times 1$     $n \times n$     $n \times k$

$$H_0: R'\beta - r = 0 \quad \text{rank}(R) = q \leq k$$

$k \times q$

$$\hat{\beta} = (X'X)^{-1} X'y \quad \text{stimatore OLS (non vincolato)}$$

$$F_m := \frac{(R'\hat{\beta} - r)' [R'(X'X)^{-1}R]^{-1} (R'\hat{\beta} - r) / q}{\hat{\sigma}^2}, \quad \hat{\sigma}^2 := \frac{\hat{\varepsilon}'\hat{\varepsilon}}{n-k}, \quad \hat{\varepsilon} = y - X\hat{\beta}$$

$$\tilde{\beta} = \hat{\beta}_{RLS} = \hat{\beta} - (X'X)^{-1} R [R'(X'X)^{-1}R]^{-1} (R'\hat{\beta} - r)$$

$$\tilde{\varepsilon} := y - X\tilde{\beta} \quad (\text{residui modello vincolato})$$

## Proprietà dei residui $\tilde{\varepsilon}$

$M_X = I_n - X(X'X)^{-1}X'$  → proietta sul sottospazio ortogonale a  $X$

$M_X \tilde{\varepsilon} =$  residui della regressione di  $\tilde{\varepsilon}$  su  $X$

$$M_X \tilde{\varepsilon} = M_X (y - X\tilde{\beta}) = \underbrace{M_X y}_0 - \underbrace{M_X X \tilde{\beta}}_0 = M_X \varepsilon = \hat{\varepsilon}$$

Consideriamo  $\tilde{\varepsilon}'\tilde{\varepsilon}$  (somma quadrati residui modello vincolato):

$$\tilde{\varepsilon}'\tilde{\varepsilon} = \tilde{\varepsilon}'(I_n)\tilde{\varepsilon} = \tilde{\varepsilon}'(P_X + M_X)\tilde{\varepsilon} \quad \text{in quanto } M_X = I_n - P_X$$

$$= \tilde{\varepsilon}'P_X\tilde{\varepsilon} + \tilde{\varepsilon}'M_X\tilde{\varepsilon}$$

$$= \tilde{\varepsilon}'P_X\tilde{\varepsilon} + \hat{\varepsilon}'\hat{\varepsilon} \quad \text{in quanto } \tilde{\varepsilon}'M_X\tilde{\varepsilon} = (M_X\tilde{\varepsilon})'(M_X\tilde{\varepsilon}) = \hat{\varepsilon}'\hat{\varepsilon}$$

Quindi:

$$\tilde{\varepsilon}'\tilde{\varepsilon} - \hat{\varepsilon}'\hat{\varepsilon} = \tilde{\varepsilon}'P_X\tilde{\varepsilon}$$

Abbiamo

$$P_X\tilde{\varepsilon} = P_X(y - X\tilde{\beta}) = P_X y - P_X X\tilde{\beta} = X \underbrace{(X'X)^{-1}X' y}_{\hat{\beta}} - X\tilde{\beta}$$

$$= X \hat{\beta} - X \tilde{\beta} = X(\hat{\beta} - \tilde{\beta})$$

da cui

$$\tilde{\varepsilon}' P_X \tilde{\varepsilon} = (P_X \tilde{\varepsilon})' (P_X \tilde{\varepsilon}) = (\hat{\beta} - \tilde{\beta})' X' X (\hat{\beta} - \tilde{\beta})$$

dove

$$\hat{\beta} - \tilde{\beta} = (X'X)^{-1} R [R'(X'X)^{-1}R]^{-1} (R'\hat{\beta} - r)$$

Quindi

$$(\hat{\beta} - \tilde{\beta})' X' X (\hat{\beta} - \tilde{\beta}) = (R'\hat{\beta} - r)' [R'(X'X)^{-1}R]^{-1} R'(X'X)^{-1} X'X (X'X)^{-1} R \cdot [R'(X'X)^{-1}R]^{-1} (R'\hat{\beta} - r)$$

$$= (R'\hat{\beta} - r)' [R'(X'X)^{-1}R]^{-1} (R'\hat{\beta} - r)$$

che corrisponde al numeratore della statistica  $F$  (moltiplicato per  $q$ )

Possiamo quindi concludere che:

Proprietà:

$$F_w = \frac{(\tilde{\varepsilon}'\tilde{\varepsilon} - \hat{\varepsilon}'\hat{\varepsilon})/q}{\hat{\varepsilon}'\hat{\varepsilon}/(n-k)}$$

Il test  $F$  valuta se l'incremento di variabilità residua che si manifesta passando dal modello non vincolato al modello vincolato sia significativo.

Note: 
$$F_w = \frac{(\tilde{\varepsilon}'\tilde{\varepsilon} - \hat{\varepsilon}'\hat{\varepsilon})/q}{\hat{\varepsilon}'\hat{\varepsilon}/(n-k)} = \frac{n-k}{q} \cdot \frac{\tilde{\varepsilon}'\tilde{\varepsilon} - \hat{\varepsilon}'\hat{\varepsilon}}{\hat{\varepsilon}'\hat{\varepsilon}}$$

$$R_n^2 := 1 - \frac{\hat{\varepsilon}'\hat{\varepsilon}}{D_n}$$

$$D_n = \text{devianza totale} = (y - \bar{y} \mathbf{1}_n)' (y - \bar{y} \mathbf{1}_n)$$
$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i, \quad \mathbf{1}_n = (1, 1, \dots, 1)'$$

$$\tilde{R}_n^2 = 1 - \frac{\tilde{\varepsilon}'\tilde{\varepsilon}}{D_n}$$

$R^2$  del modello vincolato.

Quindi:

$$\begin{aligned}
 F_n &= \frac{n-k}{q} \cdot \frac{\left( \frac{\sum \tilde{\varepsilon}^2 - \frac{(\sum \tilde{\varepsilon})^2}{n}}{\sum \hat{\varepsilon}^2} \right)}{\frac{\sum \tilde{\varepsilon}^2}{D_n} - \frac{\frac{(\sum \hat{\varepsilon})^2}{n}}{D_n}} \\
 &= \frac{n-k}{q} \cdot \frac{\left( 1 - \frac{\sum \hat{\varepsilon}^2}{D_n} \right) - \left( 1 - \frac{\sum \tilde{\varepsilon}^2}{D_n} \right)}{1 - \left( 1 - \frac{\sum \hat{\varepsilon}^2}{D_n} \right)}
 \end{aligned}$$

$$F_n = \frac{n-k}{q} \cdot \frac{\hat{R}_n^2 - \tilde{R}_n^2}{1 - \hat{R}_n^2}$$

# Stime di massima verosimiglianza

Esempio [LOCATION MODEL]

$$y_i = \mu + \varepsilon_i, \quad \varepsilon_i \sim \text{iid}(0, \sigma^2), \quad 0 < \sigma^2 < \infty$$


$$\begin{array}{l} \text{Lo stimatore OLS di } \mu \text{ è } \hat{\mu} = \bar{y}_n = \frac{1}{n} \sum_{i=1}^n y_i \\ \text{" " " " } \sigma^2 \text{ è } \hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \hat{\mu})^2 \end{array}$$

Ipotesiamo che  $\varepsilon_i$  sia gaussiano

$$\varepsilon_i \sim \text{i.i.d. } N(0, \sigma^2)$$

Notiamo che queste ipotesi implicano anche che:

$$y_i \sim \text{iid. } N(\mu, \sigma^2)$$



La funzione di densità di  $y_i$  è:

$$f_{y_i}(y; \theta) := \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{1}{2\sigma^2}(y-\mu)^2\right\}$$

dove  $\theta := (\mu, \sigma^2)'$  [vettore dei parametri-da stimare]

La funzione di densità congiunta di  $y_1, y_2, \dots, y_n$  è:

$$\begin{aligned} f_{y_1, y_2, \dots, y_n}(y_1, y_2, \dots, y_n; \theta) &= \prod_{i=1}^n f_{y_i}(y_i; \theta) \quad [\text{per l'ipotesi di indip}] \\ &= (2\pi)^{-n/2} (\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mu)^2\right\} \end{aligned}$$

$$f: \mathbb{R}^n \rightarrow \mathbb{R}^+ \cup \{0\}$$

Definiamo la **funzione di verosimiglianza** come la f. di densità congiunta in cui fissiamo  $y_1, y_2, \dots, y_n$  ai corrispondenti valori campionari - La f.d.v. è funzione di  $\theta = (\mu, \sigma^2)'$  -

$$L(\theta) = f_{y_1, \dots, y_n}(y_1, y_2, \dots, y_n; \theta) \quad L: \mathbb{R}^k \rightarrow \mathbb{R}^+ \cup \{0\}$$

↑  
valori campionari

Lo **stimate di massima verosimiglianza** è il punto  $\hat{\theta}_n$  dello spazio dei parametri che rende massima  $L(\theta)$ :

$$\hat{\theta}_n := \underset{\theta \in \Theta}{\operatorname{argmax}} L(\theta)$$

$\Theta$  = spazio dei parametri  
( $\Theta = \mathbb{R} \times \mathbb{R}^+$  nel nostro caso)



Per trovare  $\hat{\theta}_n$  è utile lavorare con la log-verosimiglianza:

$$\begin{aligned} l(\theta) &:= \log L(\theta) = \log f_{Y_1, \dots, Y_n}(y_1, \dots, y_n; \theta) \\ &= \log \prod_{i=1}^n f_{Y_i}(y_i; \theta) = \sum_{i=1}^n \underbrace{\log f_{Y_i}(y_i; \theta)}_{l_i(\theta)} \end{aligned}$$

Poiché  $\log(x)$  è una funzione monotona,

$$\hat{\theta}_n = \operatorname{argmax}_{\theta \in \Theta} L(\theta) = \operatorname{argmax}_{\theta \in \Theta} l(\theta)$$

Nel nostro esempio,

$$l_i(\theta) = \log f_{Y_i}(y_i) = \log \left[ \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(y_i - \mu)^2} \right] = -\frac{1}{2} \log(2\pi) - \frac{1}{2} \log \sigma^2 - \frac{1}{2\sigma^2}(y_i - \mu)^2$$

da cui

$$l(\theta) = \sum_{i=1}^n l_i(\theta) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mu)^2, \quad \theta = \begin{pmatrix} \mu \\ \sigma^2 \end{pmatrix}$$

Calcoliamo  $\hat{\theta}_n = (\hat{\mu}, \hat{\sigma}^2)'$  nel nostro location model.

Notiamo subito che massimizzare  $l(\theta)$  rispetto a  $\mu$  equivale a minimizzare

$$\sum_{i=1}^n (y_i - \mu)^2$$

che corrisponde al problema dei minimi quadrati:

$$\hat{\mu} = \bar{y}_n = \frac{1}{n} \sum_{i=1}^n y_i$$

$$f(x) = \log x + \frac{1}{x} a$$

La log-vero-simiglianza, massimizzata rispetto a  $\mu$ , diventa:

$$l(\hat{\mu}, \sigma^2) = -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \bar{y}_n)^2,$$

da massimizzare rispetto a  $\sigma^2$ . La derivata prima è:

$$\frac{\partial l(\hat{\mu}, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (y_i - \bar{y}_n)^2 = 0$$

(in quanto  $\sigma^2 \neq 0$ )

$$\frac{\partial}{\partial x} \log x = \frac{1}{x}$$

$$\frac{\partial}{\partial x} x^{-1} = -\frac{1}{x^2}$$

$$\frac{1}{\sigma^2} \sum_{i=1}^n (y_i - \bar{y}_n)^2 = n$$

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - \bar{y}_n)^2}{n}$$

Riassumendo

$$\hat{\theta}_n = \begin{pmatrix} \hat{\mu} \\ \hat{\sigma}^2 \end{pmatrix}, \quad \hat{\mu} = \bar{y}_n = \frac{1}{n} \sum y_i, \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_n)^2$$

$=$  stimatore OLS  $\neq$  dello stimatore OLS:

$$\frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y}_n)^2$$

note: lo stimatore ML (maximum likelihood) non è in generale consistente.

note lo stimatore ML di  $\mu$  coincide con lo stimatore OLS,  $\bar{y}_n$ .  
Può avere buone proprietà (in questo caso: B.L.U.E.)  
anche se  $\varepsilon_i$  non è normale

Consideriamo ora un generico modello di regressione lineare

$$y = X\beta + \varepsilon, \quad E[\varepsilon|X] = 0, \quad V[\varepsilon|X] = E[\varepsilon\varepsilon'|X] = \sigma^2 I_n$$

$n \times 1$     $n \times k$     $k \times 1$     $n \times 1$     $n \times 1$     $n \times n$     $n \times 1$     $1 \times n$     $n \times n$

Stimatore OLS:  $\hat{\beta} = (X'X)^{-1} X'y$ ,  $\hat{\sigma}^2 = \frac{\hat{\varepsilon}'\hat{\varepsilon}}{n-k}$ ,  $\hat{\varepsilon} := y - X\hat{\beta}$

Ipotizziamo che  $\varepsilon|X$  (o, equivalentemente,  $y|X$ ) sia gaussiano:

$$\varepsilon|X \sim N(0, \sigma^2 I_n)$$

$n \times 1$     $n \times 1$     $n \times n$

ovvero:

$$y|X \sim N(X\beta, \sigma^2 I_n)$$

$\Rightarrow$   $y_i$  e  $y_j$ , dato  $X$ ,  
sono indipendenti  
( $i \neq j$ )

La funzione di densità di  $y$  (dato  $X$ ) corrisponde alle f. di densità delle variabili multivariate:

$$\begin{aligned}
 f_{y|X}(y; \beta, \sigma^2) &= \prod_{i=1}^n f_{y_i|X}(y_i; \beta, \sigma^2) \\
 &= \prod_{i=1}^n \underbrace{\frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{1}{2\sigma^2}(y_i - x_i'\beta)^2\right\}}_{y_i|X \sim N(x_i'\beta, \sigma^2)}
 \end{aligned}$$

La log-verosimiglianza è quindi:

$$\ell(\theta) = \ell(\beta, \sigma^2) = -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \underbrace{\sum_{i=1}^n (y_i - x_i'\beta)^2}_{(y - X\beta)'(y - X\beta)}$$

$\theta = \begin{pmatrix} \beta \\ \sigma^2 \end{pmatrix}$  vettore dei parametri  
 $(k+1) \times 1$

nota:  $l(\theta) = \sum_{i=1}^n \underbrace{\log f_{y_i|x}(y_i; \theta)}_{l_i(\theta)} = \sum_{i=1}^n l_i(\theta)$

$$l_i(\theta) = -\frac{1}{2} \log 2\pi - \frac{1}{2} \log \sigma^2 - \frac{1}{2\sigma^2} (y_i - x_i' \beta)^2$$

(contributo unito i-esimo alle log-verosimiglianze complete)

Vogliamo trovare  $\hat{\theta} := \begin{pmatrix} \hat{\beta} \\ \hat{\sigma}^2 \end{pmatrix} := \underset{\theta \in \Theta}{\operatorname{arg\,max}} l(\theta)$

Esaminando  $L(\theta)$  notiamo che il  $\beta$  che massimizza  $L(\theta)$  è il  $\beta$  che minimizza

$$Q(\beta) = (y - X\beta)'(y - X\beta)$$

ovvero

$$\hat{\beta}_{OLS} := (X'X)^{-1} X'y \quad (\text{richiede } \operatorname{rank}(X) = k = \max)$$

Sostituendo  $\beta$  con  $\hat{\beta}$  otteniamo la log-verosimiglianza (concentrata rispetto a  $\beta$ ):

$$\begin{aligned}l^c(\sigma^2) &= l(\hat{\beta}, \sigma^2) = -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} (y - X\hat{\beta})'(y - X\hat{\beta}) \\ &= -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \underbrace{\hat{\varepsilon}'\hat{\varepsilon}}_{\text{devianza residua}} \quad (\hat{\varepsilon} := y - X\hat{\beta})\end{aligned}$$

$l^c(\sigma^2)$  è derivabile rispetto a  $\sigma^2$ :

$$\frac{\partial l^c(\sigma^2)}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \hat{\varepsilon}'\hat{\varepsilon} = 0$$

$$-\frac{\hat{\varepsilon}'\hat{\varepsilon}}{2} \cdot \left[ \frac{\partial}{\partial \sigma^2} (\sigma^2)^{-1} \right]$$

da cui

$$\hat{\sigma}^2 = \frac{\hat{\varepsilon}'\hat{\varepsilon}}{n} \quad \left( \neq \hat{\sigma}_{OLS}^2 = \frac{\hat{\varepsilon}'\hat{\varepsilon}}{n-k} \right)$$

Il massimo di  $l(\theta)$ , ovvero  $l(\hat{\theta}) = l(\hat{\beta}, \hat{\sigma}^2)$  è dato da:

$$l(\hat{\theta}) = -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \hat{\sigma}^2 - \frac{1}{2\hat{\sigma}^2} \sum_{i=1}^n \varepsilon_i^2$$

$$= -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \hat{\sigma}^2 - \frac{n}{2}$$


$$\frac{\sum_{i=1}^n \varepsilon_i^2}{\hat{\sigma}^2} = \frac{n \cdot \hat{\sigma}^2}{\hat{\sigma}^2} = n$$

Il massimo dipende solo da  $\hat{\sigma}^2$


Caso generale  $n$  osservazioni,  $l(\theta) = \sum_{i=1}^n l_i(\theta)$  log- $v$ .

$\theta \in \Theta$  (spazio dei parametri)


$n \times 1$



(a)



(b)



(c)



Conditione neppure: Indicando con  $\theta_0$  il valore vero di  $\theta$ ,  
allora

$$\theta_0 \in \Theta$$

$$E[l(\theta_0)] > E[l(\theta)], \text{ per ogni } \theta \in \Theta \setminus \{\theta_0\}$$

(escludere il caso (c)) - Per  $n$  grande -

Se  $l(\theta)$  è derivabile, possiamo considerare la derivata  
prima (SCORE):

$$s(\theta) := \frac{\partial l(\theta)}{\partial \theta} = \frac{\partial}{\partial \theta} \sum_{i=1}^n l_i(\theta) = \sum_{i=1}^n \frac{\partial}{\partial \theta} l_i(\theta) = \sum_{i=1}^n s_i(\theta)$$

$m \times 1$

$$s(\theta) = \frac{\partial l(\theta)}{\partial \theta} = \begin{bmatrix} \frac{\partial l(\theta)}{\partial \theta_1} \\ \vdots \\ \frac{\partial l(\theta)}{\partial \theta_m} \end{bmatrix}$$

lo score è  $m \times 1$

Se  $l(\theta)$  è derivabile, il punto di massimo  $\hat{\theta}$  deve soddisfare:

$$s(\hat{\theta}) = 0$$

(condizione del primo ordine)

Nel nostro esempio (modello lineare)

$$s(\theta) = \sum_{i=1}^n s_i(\theta) = \sum_{i=1}^n \begin{pmatrix} \frac{\partial l_i(\theta)}{\partial \beta} \\ \frac{\partial l_i(\theta)}{\partial \sigma^2} \end{pmatrix} = \sum_{i=1}^n s_i(\theta)$$

$$\frac{\partial a'x}{\partial x} = \frac{\partial x'a}{\partial x} = a$$

$$\begin{aligned} \frac{\partial l_i(\theta)}{\partial \beta} &= \frac{\partial}{\partial \beta} \left[ -\frac{1}{2} \log 2\pi - \frac{1}{2} \log \sigma^2 - \frac{1}{2\sigma^2} (y_i - x_i' \beta)^2 \right] \\ &= -\frac{1}{2\sigma^2} \frac{\partial}{\partial \beta} (y_i - x_i' \beta)^2 = -\frac{1}{2\sigma^2} 2(y_i - x_i' \beta) \frac{\partial}{\partial \beta} (-x_i' \beta) \\ &= \frac{1}{\sigma^2} \cdot (y_i - x_i' \beta) x_i = \frac{1}{\sigma^2} (y_i - \beta' x_i) x_i \end{aligned}$$

$$\begin{aligned} \frac{\partial l_i(\theta)}{\partial \sigma^2} &= \frac{\partial}{\partial \sigma^2} \left[ -\frac{1}{2} \log 2\pi - \frac{1}{2} \log \sigma^2 - \frac{1}{2\sigma^2} (y_i - x_i' \beta)^2 \right] \\ &= -\frac{1}{2\sigma^2} + \frac{1}{2\sigma^4} (y_i - x_i' \beta)^2 = \frac{1}{2\sigma^2} \left( \frac{(y_i - x_i' \beta)^2}{\sigma^2} - 1 \right) \end{aligned}$$

Quindi

$$s_i(\theta) = s_i \left( \begin{pmatrix} \beta \\ \sigma^2 \end{pmatrix} \right) = \frac{1}{\sigma^2} \begin{bmatrix} (y_i - \beta' x_i) x_i \\ \frac{1}{2} \left( \frac{(y_i - x_i' \beta)^2}{\sigma^2} - 1 \right) \end{bmatrix}$$

e

$$s(\theta) = \sum_{i=1}^n s_i(\theta) = \frac{1}{\sigma^2} \begin{bmatrix} \sum_{i=1}^n (y_i - \beta' x_i) x_i \\ \frac{1}{2} \sum_{i=1}^n \left[ \frac{(y_i - x_i' \beta)^2}{\sigma^2} - 1 \right] \end{bmatrix}$$

Per risolvere le condizioni del primo ordine  $s(\theta) = 0$

Il primo blocco è

$$\sum_{i=1}^n (y_i - \beta' x_i) x_i = 0, \text{ da cui}$$

$$\sum_{i=1}^n x_i (y_i - x_i' \beta) = 0$$

$$\sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i x_i' \beta = 0$$

$$\left( \sum_{i=1}^n x_i x_i' \right) \beta = \sum_{i=1}^n x_i y_i \quad \text{se } \sum_{i=1}^n x_i x_i' \text{ ha rango}$$

$$\hat{\beta} = \left( \sum_{i=1}^n x_i x_i' \right)^{-1} \left( \sum_{i=1}^n x_i y_i \right) = (X'X)^{-1} X'y$$

Il secondo blocco è:

$$\sum_{i=1}^n \left[ \frac{(y_i - x_i' \beta)^2}{\sigma^2} - 1 \right] = 0$$

$$\sum_{i=1}^n (y_i - x_i' \hat{\beta})^2 - n\sigma^2 = 0$$

$$\hat{\sigma}^2 = \frac{\sum (y_i - x_i' \hat{\beta})^2}{n} = \frac{\sum \hat{\varepsilon}_i^2}{n}, \quad \hat{\varepsilon}_i = y_i - x_i' \hat{\beta}$$
$$= \frac{\hat{\beta}' \hat{\beta}}{n}$$

nota allo stesso risultato si arriva usando la notazione compatta:

$$l(\theta) = -\frac{n}{2} \log \bar{u} - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \underbrace{(y - X\beta)'(y - X\beta)}_{y'y - 2\beta'X'y + \beta'X'X\beta}$$

$$s(\theta) = \begin{pmatrix} \frac{\partial l(\theta)}{\partial \beta} \\ \frac{\partial l(\theta)}{\partial \sigma^2} \end{pmatrix}, \text{ dove}$$

$$\frac{\partial l(\theta)}{\partial \beta} = -\frac{1}{2\sigma^2} (-2X'y + 2X'X\beta) = \frac{1}{\sigma^2} (X'y - X'X\beta)$$

$$\frac{\partial l(\theta)}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} (y - X\beta)'(y - X\beta)$$

Risolvendo  $s(\theta) = 0$  otteniamo

$$\left\{ \begin{array}{l} X'y - X'X\beta = 0 \\ n\sigma^2 - (y - X\beta)'(y - X\beta) = 0 \end{array} \right. \left\{ \begin{array}{l} \hat{\beta} = (X'X)^{-1} X'y \\ \hat{\sigma}^2 = \frac{\sum \hat{\varepsilon}^2}{n} \end{array} \right.$$

Conditione del secondo ordine: se  $l(\theta)$  è derivabile due volte, allora

$$H(\theta) := \frac{\partial^2}{\partial \theta \partial \theta'} l(\theta) \text{ deve essere}$$

negativa definita nel punto di minimo:

$H(\hat{\theta})$  negativa definita.

[  $H$  si chiama matrice **hessiana** ]

$$x'Ax < 0$$

$$x'(-I_n)x = -\underbrace{x'x}_{>0} < 0$$

La matrice hessiana è definita come:

$$H(\theta) = \frac{\partial^2}{\partial \theta \partial \theta'} l(\theta) = \begin{bmatrix} \frac{\partial^2 l(\theta)}{(\partial \theta_1)^2} & \frac{\partial^2 l(\theta)}{\partial \theta_1 \partial \theta_2} & \dots & \frac{\partial^2 l(\theta)}{\partial \theta_1 \partial \theta_m} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 l(\theta)}{\partial \theta_m \partial \theta_1} & \frac{\partial^2 l(\theta)}{\partial \theta_m \partial \theta_2} & \dots & \frac{\partial^2 l(\theta)}{(\partial \theta_m)^2} \end{bmatrix}$$

Note: una quantità importante (in statistica) è la matrice di informazione di Fisher

$$I_n(\theta) := -E[H(\theta)]$$

Se il modello è correttamente specificato

$$I_n(\theta) = -E[H(\theta)] = E[s(\theta)s(\theta)']$$

(information equality)

Se  $n \rightarrow \infty$ , sotto certe condizioni

$$\frac{1}{n} I_n(\theta) \rightarrow I_\infty(\theta)$$

$I_\infty(\theta)$  è la matrice di informazione asintotica

Teorema sotto alcune condizioni di regolarità, lo stimatore di massima verosimiglianza:

$$\hat{\theta} \xrightarrow{P} \theta_0 \quad (\text{consistenza})$$

$$\sqrt{n}(\hat{\theta} - \theta_0) \xrightarrow{d} N(0, V) \quad (\text{normalità asintotica})$$

$$V = I_\infty^{-1}(\theta_0) \quad (\text{efficienza})$$



Esercizio: calcolare, per il modello lineare

$$H(\theta)$$

e notare che  $H(\hat{\theta})$  è definita negativa

Nota: se il modello è correttamente specificato, allora

$$E[S(\theta_0)] = 0$$

Esercizio: calcolare  $E[S(\theta_0)]$  e  $V[S(\theta_0)]$  per il modello lineare.

## Modello lineare — svolto

$$S(\theta) = \sum_{i=1}^n s_i(\theta) = \sum_{i=1}^n \underbrace{\begin{bmatrix} \frac{1}{\sigma^2} (y_i - \beta' x_i) x_i \\ \frac{1}{2\sigma^2} \left( \frac{(y_i - x_i' \beta)^2}{\sigma^2} - 1 \right) \end{bmatrix}}_{s_i(\theta)}$$

Se  $\theta = \theta_0$  (valore vero), allora  $y_i - \beta' x_i = \varepsilon_i$  e lo scarto diventa

$$s(\theta_0) = \sum_{i=1}^n \begin{bmatrix} \frac{1}{\sigma^2} \varepsilon_i x_i \\ \frac{1}{2\sigma^2} \left( \frac{\varepsilon_i^2}{\sigma^2} - 1 \right) \end{bmatrix},$$

e quindi  $E(S(\theta_0)) = 0$  in quanto  $E[\varepsilon_i x_i] = 0$  e  $E\left[\frac{\varepsilon_i^2}{\sigma^2} - 1\right] = 0$ .

Consideriamo il Hessiano:

$$H(\theta) = \sum_{i=1}^n H_i(\theta), \quad H_i(\theta) := \frac{\partial^2}{\partial \theta \partial \theta'} l_i(\theta) = \frac{\partial^2}{\partial \theta \partial \theta'} s_i(\theta).$$

Abbiamo:

$$H_i(\theta) = \frac{\partial}{\partial \theta'} s_i(\theta) = \frac{\partial}{\partial (\beta' \sigma^2)} \begin{bmatrix} \frac{1}{\sigma^2} (y_i - \beta' x_i) x_i \\ \frac{1}{2\sigma^2} \left( \frac{(y_i - x_i' \beta)^2}{\sigma^2} - 1 \right) \end{bmatrix} = \begin{bmatrix} -\frac{1}{\sigma^2} x_i x_i' & -\frac{1}{\sigma^4} x_i (y_i - \beta' x_i) \\ -\frac{1}{\sigma^4} (y_i - \beta' x_i) x_i' & \frac{1}{2\sigma^4} - \frac{1}{\sigma^6} (y_i - x_i' \beta)^2 \end{bmatrix}$$

da cui

$$H(\theta) = \sum_{i=1}^n H_i(\theta) = \begin{bmatrix} -\frac{1}{\sigma^2} \sum x_i x_i' & -\frac{1}{\sigma^4} \sum x_i (y_i - \beta' x_i) \\ -\frac{1}{\sigma^4} \sum (y_i - \beta' x_i) x_i' & \frac{n}{2\sigma^4} - \frac{1}{\sigma^6} \sum (y_i - x_i' \beta)^2 \end{bmatrix} = \begin{bmatrix} -\frac{1}{\sigma^2} X'X & -\frac{1}{\sigma^4} [X'y - X'X\beta] \\ -\frac{1}{\sigma^4} [y'X - \beta'X'X] & \frac{n}{2\sigma^4} - \frac{1}{\sigma^6} (y - X\beta)'(y - X\beta) \end{bmatrix}$$

In corrispondenza di  $\theta = \hat{\theta}$ , abbiamo  $y_i - \beta' x_i = \hat{\epsilon}_i$  e otteniamo:

$$H_i(\hat{\theta}) = \frac{1}{\hat{\sigma}^2} \begin{bmatrix} -x_i x_i' - \frac{1}{\hat{\sigma}^2} \hat{\epsilon}_i x_i \\ -\frac{1}{\hat{\sigma}^2} x_i' \hat{\epsilon}_i & \frac{1}{2\hat{\sigma}^2} - \frac{\hat{\epsilon}_i^2}{\hat{\sigma}^4} \end{bmatrix} = -\frac{1}{\hat{\sigma}^4} \begin{bmatrix} \hat{\sigma}^2 x_i x_i' & \hat{\epsilon}_i x_i \\ \hat{\epsilon}_i x_i' & \frac{1}{2} - \frac{\hat{\epsilon}_i^2}{\hat{\sigma}^2} \end{bmatrix}$$

Sommando:

$$H(\hat{\theta}) = \sum_{i=1}^n H_i(\hat{\theta}) = -\frac{1}{\hat{\sigma}^4} \begin{bmatrix} \hat{\sigma}^2 \sum x_i x_i' & \sum \hat{\epsilon}_i x_i \\ \sum \hat{\epsilon}_i x_i' & \frac{n}{2} - \frac{\sum \hat{\epsilon}_i^2}{\hat{\sigma}^2} \end{bmatrix} = -\frac{1}{\hat{\sigma}^4} \begin{bmatrix} \hat{\sigma}^2 X'X & 0 \\ 0 & -\frac{n}{2} \end{bmatrix}$$

$$= - \begin{bmatrix} \frac{1}{\hat{\sigma}^2} X'X & 0 \\ 0 & \frac{n}{2\hat{\sigma}^4} \end{bmatrix}$$

in quanto **IMPORTANTE!**  $\sum_{i=1}^n \hat{\varepsilon}_i x_i = X' \hat{\varepsilon} = X' M_X \varepsilon = 0$  - Quindi,  $H(\hat{\theta})$  è negative definite, per cui  $\hat{\theta}$  è il punto di massimo

In corrispondente di  $\theta_0$ , l'hessiano diventa:

$$H(\theta_0) = \begin{bmatrix} -\frac{1}{\sigma^2} X'X & -\frac{1}{\sigma^4} X'\varepsilon \\ \frac{1}{\sigma^4} \varepsilon'X & \frac{n}{2\sigma^4} - \frac{1}{\sigma^6} \varepsilon'\varepsilon \end{bmatrix}$$

e la matrice di informazione di Fisher è quindi

$$I_n(\theta) := -E[H(\theta_0)] = \begin{bmatrix} \frac{1}{\sigma^2} X'X & 0 \\ 0 & -\frac{n}{2\sigma^4} + \frac{n}{\sigma^4} \end{bmatrix} = \begin{bmatrix} \frac{1}{\sigma^2} X'X & 0 \\ 0 & \frac{n}{2\sigma^4} \end{bmatrix}$$

Il limite inferiore di Rao-Cramer è:

$$I_n(\theta)^{-1} = \begin{bmatrix} \sigma^2 (X'X)^{-1} & 0 \\ 0 & \frac{2\sigma^4}{n} \end{bmatrix}$$

Varianza dello stimatore  $\hat{\beta}$