

Stima del modello di regressione lineare

- Considereremo i modelli
 - generalizzati
 - ad errori eteroschedastici
 - classici

- Stimatori :
 - OLS (minimi quadrati ordinari)
 - MM (metodo dei momenti)
 - GLS (minimi quadrati generalizzati)
 - ML (massima verosimiglianza)

Il contesto è quello del modello lineare generalizzato:

$$y = X\beta + \varepsilon$$

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

$$E[\varepsilon | X] = 0$$

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

$$V[\varepsilon | X] = E[\varepsilon \varepsilon' | X] = \Sigma \text{ def. positive, non stocastica}$$

$n \times n$

come primo obiettivo, vogliamo stimare β (k coeff. di regressione)

Ipotesi: $\beta \in \Theta_\beta \subseteq \mathbb{R}^k$

$$y_t = \beta x_t + \varepsilon_t$$

Θ_β , lo "spazio dei parametri" è contenuto in \mathbb{R}^k ed è noto a priori.

$$\beta \geq 0$$

Indichiamo con $\tilde{\beta}$ un generico stimatore di β .

$\tilde{\beta}$ è una funzione che "mappa" i nostri dati (y, X) nello spazio dei parametri -

$\tilde{\beta}$ è quindi una funzione di y e X che ci restituisce un punto dello spazio dei parametri Θ_β .

Stimatore di minimi quadrati ordinari (OLS)

$$\tilde{\beta} \Rightarrow \text{residuo: } \tilde{\varepsilon}_i = y_i - x_i' \tilde{\beta} \quad i=1, 2, \dots, n$$

$$\text{In notazione compatta: } \tilde{\varepsilon} := y - X \tilde{\beta}$$

$$\text{Il residuo è una funzione di } \tilde{\beta}: \tilde{\varepsilon} = \varepsilon(\tilde{\beta})$$

$$\hat{E}[y|x] = X\tilde{\beta}$$

Principio dei minimi quadrati: lo stimatore OLS è il punto $\hat{\beta}$ dello spazio dei parametri che minimizza la somma dei quadrati dei residui

La somma dei quadrati dei residui è


$$Q(\tilde{\beta}) := \sum_{i=1}^n \tilde{\varepsilon}_i^2 = \sum_{i=1}^n \varepsilon_i(\tilde{\beta})^2$$

che posso anche scrivere come

$$Q(\tilde{\beta}) = \tilde{\varepsilon}' \tilde{\varepsilon} = \varepsilon(\tilde{\beta})' \varepsilon(\tilde{\beta})$$

Lo stimatore OLS è il punto di minimo di $Q(\tilde{\beta})$, con $\tilde{\beta} \in \mathbb{R}^p$:

$$\hat{\beta} := \arg \min_{\tilde{\beta} \in \mathbb{R}^p} Q(\tilde{\beta})$$



OLS minimizza le distanze (residui) tra i punti empirici e la retta ipotizzata

La "metrica" che viene usata è la somma dei quadrati dei residui

Nota: L'uso dei quadrati non è obbligatorio. Ad esempio lo stimatore LAD (least absolute deviations) minimizza

$$Q_{LAD}(\tilde{\beta}) := \sum_{i=1}^n |\tilde{\epsilon}_i|$$

ed è diverso dallo stimatore OLS.

Derivazione dello stimatore OLS

$$\tilde{\beta}, \quad \tilde{\varepsilon} := y - X\tilde{\beta}$$

$$Q(\tilde{\beta}) := \tilde{\varepsilon}'\tilde{\varepsilon} = (y - X\tilde{\beta})'(y - X\tilde{\beta})$$

Consideriamo il caso in cui $\Theta_{\beta} \equiv \mathbb{R}^K$

Otteniamo le condizioni del primo ordine, $\frac{\partial}{\partial \tilde{\beta}} Q(\tilde{\beta}) = 0$

$$\text{Poiché } Q(\tilde{\beta}) = (y' - \tilde{\beta}'X')(y - X\tilde{\beta})$$

$$\begin{aligned}
 &= \underset{1 \times 1}{y'y} - \underset{1 \times n \quad n \times K \quad K \times 1}{y'X\tilde{\beta}} - \underset{1 \times 1}{\tilde{\beta}'X'y} + \underset{1 \times 1}{\tilde{\beta}'X'X\tilde{\beta}} \\
 &= y'y - 2\tilde{\beta}'X'y + \tilde{\beta}'X'X\tilde{\beta}
 \end{aligned}$$

$$\begin{aligned}
 (y'X\tilde{\beta})' &= \\
 &= \tilde{\beta}'X'y
 \end{aligned}$$

otteniamo:

$$\frac{\partial Q(\tilde{\beta})}{\partial \tilde{\beta}} = 0 - 2 \frac{\partial}{\partial \tilde{\beta}} (\tilde{\beta}'X'y) + \frac{\partial}{\partial \tilde{\beta}} \tilde{\beta}'X'X\tilde{\beta}$$

$$(AB)' = B'A'$$

$$\begin{pmatrix} \frac{\partial Q(\tilde{\beta})}{\partial \beta_1} \\ \vdots \\ \frac{\partial Q(\tilde{\beta})}{\partial \beta_K} \end{pmatrix}$$

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

$$\frac{\partial}{\partial a} a'Ba = 2Ba$$

$$= -2 \frac{X'y}{k \times 1} + 2 \frac{X'X\tilde{\beta}}{k \times 1} = 0$$

risistema di k equazioni
in k incognite

Se $X'X$ è invertibile (ovvero se X ha rango massimo = k)
allora possiamo scrivere $n \times k$

$$X'y = X'X\tilde{\beta}$$

$$(X'X)^{-1} X'y = (X'X)^{-1} X'X\tilde{\beta}$$

$$\tilde{\beta} = (X'X)^{-1} X'y$$

$$\frac{\partial^2 Q(\beta)}{\partial \beta \partial \beta'} = \begin{pmatrix} \frac{\partial^2 Q(\beta)}{(\partial \beta_1)^2} & \frac{\partial^2 Q(\beta)}{\partial \beta_1 \partial \beta_2} & \dots \\ \vdots & \vdots & \vdots \end{pmatrix}$$

Corrisponde ad un punto di minimo:

$$\frac{\partial^2 Q(\beta)}{\partial \beta \partial \beta'} = 2X'X \quad (\text{fare i passaggi})$$

dove $X'X$ è positiva definita ($a'X'Xa > 0$, per ogni $a \neq 0$)
in quanto $\text{rank}(X) = k$.

$\tilde{\beta}$ è un punto di minimo

È inoltre unico, in quanto la funzione $Q(\tilde{\beta})$ è convessa.

Lo stimatore $\hat{\beta} = (X'X)^{-1}X'y$ è lo stimatore OLS.

note

ricordiamo che

$$X = \begin{bmatrix} \text{---} x'_1 \text{---} \\ \text{---} x'_2 \text{---} \\ \vdots \\ \text{---} x'_n \text{---} \end{bmatrix}$$

$n \times k$

dove $x_i = \begin{pmatrix} x_{i1} \\ x_{i2} \\ \vdots \\ x_{im} \end{pmatrix}$

e, analogamente,

$$y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$$

Quindi:

$$X'X = \begin{bmatrix} | & | & & | \\ x_1 & x_2 & \dots & x_n \\ | & | & & | \end{bmatrix} \begin{bmatrix} \text{---} x'_1 \text{---} \\ \text{---} x'_2 \text{---} \\ \vdots \\ \text{---} x'_n \text{---} \end{bmatrix} = x_1x'_1 + x_2x'_2 + \dots + x_nx'_n = \sum_{i=1}^n x_i x'_i$$

$$X'y = \begin{bmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_n \\ \vdots & \vdots & & \vdots \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = x_1 y_1 + x_2 y_2 + \dots + x_n y_n = \sum_{i=1}^n x_i y_i$$

Possiamo quindi scrivere

$$\begin{aligned} \hat{\beta} &= (X'X)^{-1} X'y = \left(\sum_{i=1}^n x_i x_i' \right)^{-1} \left(\sum_{i=1}^n x_i y_i \right) \\ &= \underbrace{\left(\frac{1}{n} \sum_{i=1}^n x_i x_i' \right)^{-1}}_{S_{xx}} \underbrace{\left(\frac{1}{n} \sum_{i=1}^n x_i y_i \right)}_{S_{xy}} = S_{xx}^{-1} S_{xy} \end{aligned}$$

S_{xx} è la matrice di momenti secondi di x (nel campione)
 S_{xy} " " " " " " incrociati tra x e y

Se x e y fossero espressi come deviazioni dalle rispettive medie,
 S_{xx} sarebbe la matrice di varianza e covarianza di x_i , $i=1, \dots, n$
 S_{xy} " " " " " " covarianza tra x_i e y_i , $i=1, \dots, n$

Nel caso scalare, $\hat{\beta} = \frac{\frac{1}{n} \sum x_i y_i}{\frac{1}{n} \sum x_i^2}$

Struttura OLS: residui, valori stimati, proiezioni

Ricordiamo che $\hat{\beta} = (X'X)^{-1} X'y$

Il modello teorico è $y = X\beta + \varepsilon$, ovvero $E[y|X] = X\beta$.

I residui OLS sono $\hat{\varepsilon} := y - X\hat{\beta}$ (differenza tra i valori empirici y e la retta di regressione stimata)

I valori stimati sono $\hat{y} := X\hat{\beta}$. Rappresentano la nostra stima del valore atteso condizionato $E[y|X]$:

$$\hat{y} := X\hat{\beta} = \hat{E}[y|X]$$

Notiamo che

$$y = \hat{y} + \hat{\varepsilon}$$

$$\begin{pmatrix} y = \hat{y} + \hat{\varepsilon} \\ y = X\beta + \varepsilon \end{pmatrix}$$

Consideriamo il valore atteso stimato \hat{y} . Abbiamo:

$$\hat{y} := X\hat{\beta} = \underset{n \times k}{X} \underset{k \times n}{(X'X)^{-1}} \underset{k \times n}{X'} \underset{n \times 1}{y} = \underset{n \times n}{P_X} \cdot \underset{n \times 1}{y}, \quad \underset{n \times n}{P_X} := \underset{n \times k}{X} \underset{k \times k}{(X'X)^{-1}} \underset{k \times n}{X'}$$

La matrice P_X prende il nome di "matrice di proiezione":
proietta sul sottospazio (dello spazio \mathbb{R}^m) generato da X .

Proprietà di P_X

① $\text{rank}(P_X) = K$

② "idempotente": $P_X \cdot P_X = P_X$
fore di idempotenza

nota: il rango di una matrice idempotente
è uguale alla sua traccia.

Consideriamo ora i residui OLS, $\hat{\varepsilon} = y - X\hat{\beta} = y - \hat{y}$

Abbiamo:

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

$$= (I_m - P_X) \cdot y = M_X \cdot y, \quad M_X = I_m - P_X = I_m - X(X'X)^{-1}X'$$

M_X è un'altra matrice di proiezione: proietta sul sottospazio
ortogonale a quello generato da X

Alcune proprietà:

① M_X è idempotente ($M_X \cdot M_X = M_X$) e simmetrica ($M_X' = M_X$)
(provarne per esercizio)

② M_X e P_X sono ortogonali tra loro:

$$M_X \cdot P_X = (I_n - P_X) \cdot P_X = P_X - P_X P_X = P_X - P_X = 0$$

una conseguenza della ② è che $\hat{\varepsilon}$ e \hat{y} sono tra loro ortogonali:

$$\hat{\varepsilon}' \hat{y} = (M_X \cdot y)' P_X \cdot y = y' M_X \cdot P_X \cdot y = 0 \quad \text{poiché } M_X P_X = 0$$

Abbiamo usato la simmetria di M_X

Analogamente $\hat{\varepsilon}$ è ortogonale a X :

$$\hat{\varepsilon}' X = (M_X \cdot y)' X = y' M_X \cdot X = 0 \quad \text{in quanto } M_X X = 0.$$

$$M_X \cdot X = (I_n - X(X'X)^{-1}X')X = X - X(X'X)^{-1}X'X = 0$$

(note: $P_X \cdot X = X$ (ovvero))

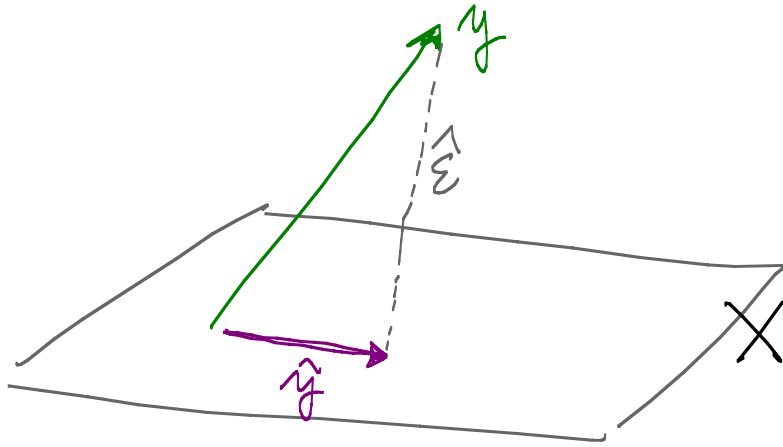
③ Se $y = X\beta + \varepsilon$, allora:

$$\hat{\varepsilon} = M_X \cdot y = M_X (X\beta + \varepsilon) = \underbrace{M_X X \beta}_0 + M_X \cdot \varepsilon = 0 + M_X \varepsilon$$

Quindi:

$$M_X \cdot y = M_X \varepsilon$$

Interpretazione grafica



$$\begin{aligned} \rightarrow \hat{y} &= P_X \cdot y \\ \text{---} \hat{\varepsilon} &= M_X \cdot y \end{aligned}$$

Note: scomposizione della devianza

$$\begin{aligned}\sum_{i=1}^n y_i^2 &= y'y = y'I_n y = y'(M_x + P_x)y \\ &= y'M_x y + y'P_x y \\ &= \hat{\varepsilon}'\hat{\varepsilon} + y'X(X'X)^+X'y \\ &= \hat{\varepsilon}'\hat{\varepsilon} + y'X(X'X)^{-1}(X'X)(X'X)^{-1}X'y \\ &= \hat{\varepsilon}'\hat{\varepsilon} + \hat{\beta}'(X'X)\hat{\beta} \\ &= \hat{\varepsilon}'\hat{\varepsilon} + (X\hat{\beta})'(X\hat{\beta}) \\ y'y &= \hat{\varepsilon}'\hat{\varepsilon} + \hat{y}'\hat{y}\end{aligned}$$

Somme dei
quadrati
totale

Somme dei
quadrati
residua

Somme dei
quadrati
spiegata

$$(y'y - n\bar{y}^2) = \hat{\varepsilon}'\hat{\varepsilon} + (\hat{y}'\hat{y} - n\bar{y}^2)$$

Devianza
totale

Devianza
residua

Devianza
spiegata

Proprietà dello stimatore OLS

Ricordiamo le ipotesi: $y = X\beta + \varepsilon$, $E(\varepsilon|X) = 0$, $V(\varepsilon|X) = \Sigma$, def. posit.
 $\text{rank}(X) = K$

Proprietà ①: correttezza

$$E(\hat{\beta}|X) = \beta$$

dimostrazione: $E(\hat{\beta}|X) = E((X'X)^{-1} X'y | X)$
 $= (X'X)^{-1} X' E[y|X] = (X'X)^{-1} X'X\beta = \beta$

dimostrazione alternativa: $E(\hat{\beta}|X) = (X'X)^{-1} X' E[y|X] = (X'X)^{-1} X' X\beta = \beta$
 $E[X\beta + \varepsilon | X] = X\beta + \underbrace{E[\varepsilon|X]}_0$

② linearità

Uno stimatore si dice lineare se può essere scritto nelle forme $\tilde{\beta} = A_X \cdot y$, dove A_X non dipende da y (è una combinazione lineare di y)

$$\hat{\beta} = (X'X)^{-1} X'y = A_X \cdot y, \quad A_X = (X'X)^{-1} X'$$

③ Variante dello stimatore OLS:

$$V(\hat{\beta}|X) = \underbrace{(X'X)^{-1}} \underbrace{X' \Sigma X (X'X)^{-1}}$$

dimostrazione:

$$\begin{aligned} V(\hat{\beta}|X) &= V\left(\underbrace{(X'X)^{-1} X'y}_{\text{lineare in } y} \middle| X\right) \\ &= (X'X)^{-1} X' \underbrace{V(y|X)}_{\Sigma} X (X'X)^{-1} \\ &= \underbrace{(X'X)^{-1} X'}_{\text{matrice}} \Sigma \underbrace{X (X'X)^{-1}}_{\text{matrice}} \end{aligned}$$

$$\begin{aligned} V(ax) &= a^2 X \\ V(AX) &= A V(X) A' \end{aligned}$$

note ①. La varianza di $\hat{\beta}$ dipende da Σ , che non è nota

② Supponiamo che $\Sigma := \text{diag} \{ \sigma_1^2, \sigma_2^2, \dots, \sigma_m^2 \}$.

In questo caso:

$$X' \Sigma X = \begin{bmatrix} x_1 & x_2 & \dots & x_m \end{bmatrix} \begin{bmatrix} \sigma_1^2 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & \dots & 0 \\ \vdots & 0 & \ddots & 0 \\ 0 & 0 & \dots & \sigma_m^2 \end{bmatrix} \begin{bmatrix} x_1' \\ x_2' \\ \vdots \\ x_m' \end{bmatrix} = \sum_{i=1}^m x_i x_i' \cdot \sigma_i^2$$

Quindi,

$$\begin{aligned} V(\hat{\beta} | X) &= \underbrace{(X'X)^{-1}} \underbrace{X' \Sigma X} \underbrace{(X'X)^{-1}} \\ &= \left(\sum x_i x_i' \right)^{-1} \left(\sum x_i x_i' \sigma_i^2 \right) \left(\sum x_i x_i' \right)^{-1} \\ &= \frac{1}{n} \left(\frac{1}{n} \sum x_i x_i' \right)^{-1} \left(\frac{1}{n} \sum x_i x_i' \sigma_i^2 \right) \left(\frac{1}{n} \sum x_i x_i' \right)^{-1} \end{aligned}$$

dipende da $\sigma_1^2, \sigma_2^2, \dots, \sigma_m^2$ (non note in generale)

③ Supponiamo che $\Sigma = \sigma^2 I_m$ (modello lineare classico)
Abbiamo:

$$\begin{aligned} V(\hat{\beta} | X) &= (X'X)^{-1} X' \Sigma X (X'X)^{-1} = (X'X)^{-1} X' (\sigma^2 I_m) X (X'X)^{-1} \\ &= \sigma^2 (X'X)^{-1} X' X (X'X)^{-1} = \sigma^2 (X'X)^{-1} \end{aligned}$$

che dipende solo da σ^2 .

Inoltre:

$$V(\hat{\beta} | X) = \sigma^2 (X'X)^{-1} = \sigma^2 \left(\sum_{i=1}^n x_i x_i' \right)^{-1} = \frac{\sigma^2}{n} \left(\frac{1}{n} \sum_{i=1}^n x_i x_i' \right)^{-1}$$

Riassunto su OLS.

Lo stimatore OLS risolve il problema di minimo

$$\hat{\beta} := \arg \min_{\tilde{\beta} \in \mathbb{R}^p} \varepsilon(\tilde{\beta})' \varepsilon(\tilde{\beta}), \quad \varepsilon(\tilde{\beta}) := y - X\tilde{\beta}$$

- La soluzione è:

$$\hat{\beta} = (X'X)^{-1} X'y = S_{xx}^{-1} S_{xy}, \quad S_{xx} = \frac{1}{n} X'X = \frac{1}{n} \sum x_i x_i'$$
$$S_{xy} = \frac{1}{n} X'y = \frac{1}{n} \sum x_i y_i'$$

- Lo stimatore OLS scompone y in due parti ortogonali tra loro, \hat{y} (valore atteso stimato) e $\hat{\varepsilon}$ (residuo)

- $\hat{\beta}$ è uno stimatore lineare (comb. lineare di y)

- Sotto le ipotesi del modello lineare generalizzato,

$$E(\hat{\beta}|X) = \beta \quad (\text{correttezza})$$

$$V(\hat{\beta}|X) = (X'X)^{-1} X' \Sigma X (X'X)^{-1}$$


Se $\Sigma = \sigma^2 I_n$ (ML classico), allora $V(\hat{\beta}|X) = \sigma^2 (X'X)^{-1}$

Stime GLS (generalized least squares)

OLS risolve un problema di minimo dove tutte le osservazioni hanno lo stesso peso:

$$\varepsilon(\tilde{\beta})' \varepsilon(\tilde{\beta}) = \sum_{i=1}^n (y_i - x_i' \tilde{\beta})^2 = \min$$

GLS pesa le osservazioni in funzione di quanto influenzare sulla retta di regressione incognita solo in grado di potere.



Fondamente:

$$\hat{\beta}_{GLS} := \underset{\tilde{\beta} \in \mathbb{R}^p}{\operatorname{argmin}} \underbrace{\varepsilon(\tilde{\beta})' \Sigma^{-1} \varepsilon(\tilde{\beta})}_{1 \times n \quad n \times n \quad n \times 1}$$

Indicando con σ^{ij} il generico elemento di Σ^{-1} , la stime GLS può essere anche scritta come

$$\hat{\beta}_{GLS} := \underset{\tilde{\beta} \in \mathbb{R}^p}{\operatorname{argmin}} \sum_{i=1}^n \sum_{j=1}^n (y_i - x_i' \tilde{\beta})(y_j - x_j' \tilde{\beta}) \cdot \sigma^{ij} = \underset{\tilde{\beta} \in \mathbb{R}^p}{\operatorname{argmin}} \sum_i \sum_j \tilde{\varepsilon}_i \tilde{\varepsilon}_j \sigma^{ij}$$

nota: Se $\Sigma := \text{diag} \{ \sigma_1^2, \sigma_2^2, \dots, \sigma_n^2 \}$ (ML eteroschedastic)
allora

$$\Sigma^{-1} = \text{diag} \left\{ \frac{1}{\sigma_1^2}, \frac{1}{\sigma_2^2}, \dots, \frac{1}{\sigma_n^2} \right\}$$

Quindi,

$$\sigma^{ij} = \begin{cases} 0 & \text{se } i \neq j \\ 1/\sigma_i^2 & \text{se } i = j \end{cases}$$

e

$$\hat{\beta}_{OLS} = \underset{\tilde{\beta} \in \mathbb{R}^p}{\text{argmin}} \sum_{i=1}^n \frac{1}{\sigma_i^2} (y_i - \tilde{\beta}' x_i)^2$$

↳ ogni osservazione viene pesata con l'inverso di σ_i^2 .
(σ_i^2 grande \rightarrow poco peso)

nota: Se $\Sigma = \sigma^2 I_n$ (ML omoschedastic), allora $\Sigma^{-1} = \frac{1}{\sigma^2} I_n$ e

$$\begin{aligned} \hat{\beta}_{OLS} &:= \underset{\tilde{\beta}}{\text{argmin}} \varepsilon(\tilde{\beta})' \Sigma^{-1} \varepsilon(\tilde{\beta}) = \underset{\tilde{\beta}}{\text{argmin}} \frac{1}{\sigma^2} \varepsilon(\tilde{\beta})' \varepsilon(\tilde{\beta}) \\ &= \underset{\tilde{\beta}}{\text{argmin}} \varepsilon(\tilde{\beta})' \varepsilon(\tilde{\beta}) = \hat{\beta}_{OLS} \end{aligned}$$

Definiamo $\hat{\beta}_{OLS}$:

$$Q_{\Sigma}(\tilde{\beta}) = \underbrace{\varepsilon(\tilde{\beta})}' \Sigma^{-1} \varepsilon(\tilde{\beta})$$

Somma "generalizzata" dei
quadrati dei residui

Comunque a:

$$\begin{aligned} Q_{\Sigma}(\tilde{\beta}) &= (y - X\tilde{\beta})' \Sigma^{-1} (y - X\tilde{\beta}) = (y - X\tilde{\beta})' (\Sigma^{-1}y - \Sigma^{-1}X\tilde{\beta}) \\ &= y' \Sigma^{-1} y - \tilde{\beta}' X' \Sigma^{-1} y - y' \Sigma^{-1} X \tilde{\beta} + \tilde{\beta}' X' \Sigma^{-1} X \tilde{\beta} \\ &= y' \Sigma^{-1} y - 2 \tilde{\beta}' X' \Sigma^{-1} y + \tilde{\beta}' X' \Sigma^{-1} X \tilde{\beta} \end{aligned}$$

Le derivate prime e:

$$\frac{\partial}{\partial \tilde{\beta}} Q_{\Sigma}(\tilde{\beta}) = 0 - 2X' \Sigma^{-1} y + 2X' \Sigma^{-1} X \tilde{\beta} = 0$$

$$\frac{\partial}{\partial X} X' A = A$$

$$X' \Sigma^{-1} X \tilde{\beta} = X' \Sigma^{-1} y$$

$$\frac{\partial}{\partial X} X' A X = 2 A X$$

Ora se: $\text{rang}(X) = \max = k$
 $\text{rang}(\Sigma) = \max = m$

allora $X' \Sigma^{-1} X$ ha $\text{rang} \max = k$ ed è quindi invertibile

Infatti: se $\text{rang } \Sigma = \max$, allora $\text{rang } \Sigma^{-1} = \max$.
 Se $\text{rang } X = k = \max$, allora $\text{rang } X' \Sigma^{-1} X$ è massimo
 Quindi $X' \Sigma^{-1} X$ è invertibile

In questo caso, moltiplicando per $(X' \Sigma^{-1} X)^{-1}$, otteniamo

$$\hat{\beta}_{GLS} = (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} y$$

Lo stimatore OLS corrisponde a $\hat{\beta}_{GLS}$ per $\Sigma = I_n$

Proprietà

Se valgono le ipotesi del ML generalizzato:

① correttezza: $E(\hat{\beta}_{GLS} | X) = \beta$

dim $E[\hat{\beta}_{GLS} | X] = E[(X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} y | X]$
 $= (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} E[y | X]$
 $= \cancel{(X' \Sigma^{-1} X)^{-1}} X' \cancel{\Sigma^{-1}} X \beta = \beta$

$$V(Ax) = AV(x)A'$$

② La varianza (condizionata) di $\hat{\beta}_{GLS}$ è

$$V[\hat{\beta}_{GLS} | X] = (X' \Sigma^{-1} X)^{-1}$$

dimo: $V[\hat{\beta}_{GLS} | X] = V[(X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} y | X]$

$$= (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} V(y | X) \Sigma^{-1} X (X' \Sigma^{-1} X)^{-1}$$

$$= \cancel{(X' \Sigma^{-1} X)^{-1}} X' \cancel{\Sigma^{-1}} \Sigma \cancel{\Sigma^{-1}} X \cancel{(X' \Sigma^{-1} X)^{-1}}$$

$$= (X' \Sigma^{-1} X)^{-1}$$

note: $V(\hat{\beta}_{GLS} | X) = (X' \Sigma^{-1} X)^{-1} \neq (X' X)^{-1} X' \Sigma X (X' X)^{-1} = V(\hat{\beta}_{OLS} | X)$

vediamo che $V(\hat{\beta}_{GLS} | X) < V(\hat{\beta}_{OLS} | X)$

note: se $\Sigma = \sigma^2 I_n$, $V(\hat{\beta}_{GLS} | X) = (X' (\sigma^2 I_n)^{-1} X)^{-1}$
 $= (\sigma^2)^{-1} (X' X)^{-1} = \sigma^2 (X' X)^{-1} = V(\hat{\beta}_{OLS} | X)$

③

Teorema di Aitken

Sotto le ipotesi effettuate [ovvero: $E[y|x] = X\beta$, $V[y|x] = \Sigma$
lo stimatore OLS è
efficiente (= a minima
varianza) nelle classi degli
stimatori lineari e corretti

$$\left[\begin{array}{l} \text{rank}(X) = \text{max} = k, \\ \text{rank}(\Sigma) = \text{max} = n \end{array} \right]$$

non
stochastic

(In altre parole, $\hat{\beta}_{OLS}$ è BLUE — best linear unbiased estimator)

dimostrazione.

Abbiamo già visto che $\hat{\beta}_{OLS}$ è lineare e corretto.
Consideriamo un generico stimatore lineare:

$$\tilde{\beta} = Ay$$

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

(ad esempio, nel caso di $\hat{\beta}_{OLS}$, $\hat{\beta}_{OLS} = A \cdot y$, per $A = (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1}$)

Il valore atteso di $\tilde{\beta}$ è

$$E[\tilde{\beta}|X] = E[Ay|x] = A E[y|x] = A \cdot X\beta$$

Quindi, affinché $\tilde{\beta}$ sia corretto, A deve soddisfare $A \cdot X = I_k$.
 Calcoliamo la varianza di $\tilde{\beta}$:
 $k \times m$ $n \times k$

$$V[\tilde{\beta}|X] = V[A \cdot y|X] = AV(y|X)A' = A\Sigma A'$$

Vogliamo dimostrare che $V[\tilde{\beta}|X] = A\Sigma A' \geq (X'\Sigma^{-1}X)^{-1} = V[\hat{\beta}_{OLS}|X]$

Riscriviamo A nel seguente modo:

$$A = [(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1} + D]$$

Notiamo che la condizione di correttezza $A \cdot X = I_k$ implica che

$$A \cdot X = [(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1} + D] \cdot X = I_k + DX = I_k$$

da cui:

$$DX = 0$$

Torniamo alle varianze di $\tilde{\beta}$:

$$\begin{aligned} V[\tilde{\beta}|X] &= A \cdot \Sigma A' = [(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1} + D] \cdot \Sigma [(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1} + D]' \\ &= [(X'\Sigma^{-1}X)^{-1}X'\Sigma^{-1} + D] \Sigma [\Sigma^{-1}X(X'\Sigma^{-1}X)^{-1} + D'] \end{aligned}$$

$$(AB)' = B'A'$$

$$\begin{aligned}
&= (X' \Sigma^{-1} X)^{-1} X' \cancel{\Sigma^{-1}} \cancel{\Sigma} \cancel{\Sigma^{-1}} X (X' \Sigma^{-1} X)^{-1} \\
&+ (X' \Sigma^{-1} X)^{-1} X' \cancel{\Sigma^{-1}} \Sigma D' + D \cancel{\Sigma} \cancel{\Sigma^{-1}} X (X' \Sigma^{-1} X)^{-1} \\
&+ D \Sigma D' \\
&= (X' \Sigma^{-1} X)^{-1} + 0 + 0 + D \Sigma D' \quad (\text{in quanto } DX = 0) \\
&= V[\hat{\beta}_{GLS} | X] + D \Sigma D'
\end{aligned}$$

Quindi:

$$V[\tilde{\beta} | X] - V[\hat{\beta}_{GLS} | X] = D \Sigma D' \geq 0 \quad (\text{semidefinite positive})$$

L'uguaglianza a 0 si ottiene se $D = 0$. Ma in questo caso $\tilde{\beta} = \hat{\beta}_{GLS}$. □

Nota importante: Se $\Sigma = \sigma^2 I_n$ (modello lineare classico)

il teorema di Aitken diventa il seguente:

$$\text{Se } E[y | X] = X\beta, \quad V[y | X] = \sigma^2 I_n, \quad \text{rank}(X) = \text{max} = k$$

albre lo stimatore $\hat{\beta}_{OLS} = (X'X)^{-1}X'y$ è lo stimatore
a minime varianze nelle classe degli stimatori
lineari e corretti (B.L.U.E)

Questo è il noto teorema Gauss-Markov.

Esercizio: dimostrare Gauss-Markov facendo gli stessi passaggi
del teorema di Aitken.

Una derivazione alternativa dello stimatore GLS.

Il teorema Gauss-Markov dice che, se $E[y|X] = X\beta$
e $V[y|X] = \sigma^2 I_n$, albre OLS è lo stimatore "migliore"

Supponiamo però che $V[y|X] = \Sigma \neq \sigma^2 I_n$

Come possiamo ottenere lo stimatore BLU?

Possibile idea: trasformare la regressione $y = X\beta + \varepsilon$
in un'altra regressione che soddisfi G.M

Come mi fa:

$$y = X\beta + \varepsilon$$

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

Trasformiamo il modello usando una "matrice di trasformazione", T , di dimensione $n \times n$

$$T \cdot y = TX\beta + T\varepsilon$$

$$\tilde{y} = \tilde{X}\beta + \tilde{\varepsilon}$$

dove $\tilde{y} := Ty$, $\tilde{X} := TX$, $\tilde{\varepsilon} := T\varepsilon$.

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

Notiamo che:

$$\begin{aligned} E[\tilde{y} | \tilde{X}] &= E[\tilde{X}\beta + \tilde{\varepsilon} | X] = \tilde{X}\beta + E[\tilde{\varepsilon} | X] \\ &= \tilde{X}\beta + E[T \cdot \varepsilon | X] = \\ &= \tilde{X}\beta + T \cdot \underbrace{E[\varepsilon | X]}_0 = \tilde{X}\beta \end{aligned}$$

La "nuova" componente stocastica
risultante

$$E[\tilde{\varepsilon} | X] = 0$$

e la sua variante $\tilde{\varepsilon}$:

$$V[\tilde{\varepsilon}|X] = V[T \cdot \varepsilon | X] = T \cdot V[\varepsilon | X] \cdot T' = T \Sigma T'$$

Vogliamo T in modo che $T \cdot \Sigma \cdot T' = I_n$.

Per trovare T , scomponiamo Σ nel seguente modo:

$$\Sigma = \underset{n \times n}{Q} \cdot \underset{n \times n}{\Lambda} \underset{n \times n}{Q'}$$

dove Λ è la matrice (diagonale) degli autovalori e Q è la matrice (ortogonale) degli autovettori,

$$Q'Q = QQ' = I_n$$

Notiamo che $\Sigma^{-1} = Q \Lambda^{-1} Q'$

(infatti $\Sigma \Sigma^{-1} = Q \Lambda Q' Q \Lambda^{-1} Q' = I_n$)

e prendiamo $T := \Lambda^{-1/2} \cdot Q'$

Abbiamo che: $V[\tilde{\varepsilon}|X] = T \Sigma T' = \Lambda^{-1/2} Q' Q \Lambda Q' Q \Lambda^{-1/2}$

$$= \Lambda^{-1/2} \cdot \Lambda \Lambda^{-1/2} = I_m$$

Il modello trasformato usando $T = \Lambda^{-1/2} Q'$ soddisfa C.M.
 Lo stimatore BLU è quindi

$$\begin{aligned} \hat{\beta} &= (\tilde{X}' \tilde{X})^{-1} \tilde{X}' \tilde{y} & \tilde{X} &:= TX \\ &= (X' T' T X)^{-1} X' T' T y & \tilde{y} &:= Ty \\ &= (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} y \end{aligned}$$

in quanto: $T' T = Q \Lambda^{-1/2} \cdot \Lambda^{-1/2} Q' = Q \Lambda^{-1} Q' = \Sigma^{-1}$

Notiamo infine che

$$\begin{aligned} \hat{\beta} &= \arg \min_{\tilde{\beta}} (\tilde{y} - \tilde{X} \tilde{\beta})' (\tilde{y} - \tilde{X} \tilde{\beta}) \\ &= \arg \min_{\tilde{\beta}} (Ty - TX \tilde{\beta})' (Ty - TX \tilde{\beta}) \\ &= \arg \min_{\tilde{\beta}} (y' T' - \tilde{\beta}' X' T') (Ty - TX \tilde{\beta}) \end{aligned}$$

$$= \arg \min (\tilde{y}' - \tilde{\beta}' X') T' T (y - X \tilde{\beta})$$

$$= \arg \min (y - X \tilde{\beta})' \Sigma^{-1} (y - X \tilde{\beta}) =: \hat{\beta}_{GLS}$$

Pi capitolando

modello lineare generalizzato $y = X\beta + \varepsilon$, $E[\varepsilon|X] = 0$, $V[\varepsilon|X] = \Sigma$ d.p.

stimatore OLS $\hat{\beta}_{OLS} = (X'X)^{-1} X'y$ - corretto lineare
- non efficiente

$$V[\hat{\beta}_{OLS}|X] = (X'X)^{-1} X' \Sigma X (X'X)^{-1} \text{ non \u00e9 "minimo"}$$

stimatore GLS $\hat{\beta}_{GLS} = (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} y$ - corretto lineare
- efficiente (B.L.U.E.)

$$V[\hat{\beta}_{GLS}|X] = (X' \Sigma^{-1} X)^{-1} \text{ \u00e9 "minimo"}$$

Purtroppo, lo stimatore OLS non è sempre calcolabile:
dipende infatti da Σ .

Si parla di stime "virtuali" - In inglese: "INFEASIBLE"

Esistono alcuni casi in cui $\hat{\beta}_{OLS}$ può essere calcolato

① $\Sigma = \sigma^2 I_n$ (modello lineare classico).

In questo caso, $\hat{\beta}_{OLS} = \hat{\beta}_{OLS} = (X'X)^{-1} X'y$

② modello lineare con eteroschedasticità (esempio)

$$y_i = x_i' \beta + \varepsilon_i \quad E[\varepsilon_i | x] = 0$$

$$\sigma_i^2 = V[\varepsilon_i | x] = h \cdot z_i^2 \quad (h > 0)$$

$$\text{Cov}[\varepsilon_i, \varepsilon_j | x] = 0 \quad \forall i \neq j$$

(ipotesi che la varianza di ε_i dipende da una variabile z_i)

In forma compatta: $y = X\beta + \varepsilon$, $E[\varepsilon | X] = 0$

$$V[\varepsilon|X] = V \left[\begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix} | X \right] = \begin{bmatrix} \sigma_1^2 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_n^2 \end{bmatrix} = \begin{bmatrix} h z_1^2 & & & \\ & h z_2^2 & & \\ & & \dots & \\ & & & h z_n^2 \end{bmatrix} =$$

$$= h \begin{bmatrix} z_1^2 & & & \\ & z_2^2 & & \\ & & \dots & \\ & & & z_n^2 \end{bmatrix} = \Sigma = h \cdot \text{diag}\{z_1^2, \dots, z_n^2\}$$

Calcoliamo lo stimatore GLS:

$$X \rightarrow \begin{bmatrix} -x_1' \\ \vdots \\ -x_n' \end{bmatrix} \quad X' \rightarrow \begin{bmatrix} x_1 & \dots & x_n \end{bmatrix}$$

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

$X'X$

$$\hat{\beta}_{GLS} = (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} y$$

$$= \left[\begin{matrix} h \\ h \end{matrix} \begin{bmatrix} x_1 & x_2 & \dots & x_n \end{bmatrix} \begin{pmatrix} z_1^2 & & & \\ & z_2^2 & & \\ & & \dots & \\ & & & z_n^2 \end{pmatrix}^{-1} \begin{bmatrix} x_1' \\ x_2' \\ \vdots \\ x_n' \end{bmatrix} \right]^{-1} \left[\begin{matrix} h \\ h \end{matrix} \begin{bmatrix} x_1 & x_2 & \dots & x_n \end{bmatrix} \begin{pmatrix} z_1^2 & & & \\ & z_2^2 & & \\ & & \dots & \\ & & & z_n^2 \end{pmatrix}^{-1} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \right]$$

$$= \left(\sum_{i=1}^n \frac{1}{z_i^2} x_i x_i' \right)^{-1} \left(\sum_{i=1}^n \frac{1}{z_i^2} x_i y_i \right) \quad \left(\frac{\sum x_i x_i'}{z_i^2} \right)^{-1} \left(\frac{\sum x_i y_i}{z_i^2} \right)$$

In questo caso, $\hat{\beta}_{GLS}$ è calcolabile (FEASIBLE) e corrisponde allo stimatore dei minimi quadrati ponderati.

Il peso di ogni unità statistica è $\frac{1}{z_i^2}$ (inversa delle var. di ε_i)

Nota/esercizio: in questo caso, la matrice di trasformazione T è

$$T := \begin{bmatrix} 1/z_1 & & & \\ & 1/z_2 & & \\ & & \dots & \\ & & & 1/z_n \end{bmatrix}$$

e il modello trasformato è $(Ty) = (TX)\beta + (T\varepsilon)$
dove

$$T \cdot y = \begin{bmatrix} y_1/z_1 \\ y_2/z_2 \\ \vdots \\ y_n/z_n \end{bmatrix} \quad TX = \begin{bmatrix} x_1'/z_1 \\ x_2'/z_2 \\ \vdots \\ x_n'/z_n \end{bmatrix}$$

$$y_i = \beta' x_i + \varepsilon_i \\ \underbrace{\quad}_{(0, w \cdot z_i^2)}$$

$$\frac{y_i}{z_i} = \beta' \frac{x_i}{z_i} + \frac{\varepsilon_i}{z_i} \\ \underbrace{\quad}_{(0, w)}$$

che corrisponde alle regressioni

$$\left(\frac{y_i}{z_i} \right) = \left(\frac{x_i}{z_i} \right)' \beta + \tilde{\varepsilon}_i, \quad i=1, 2, \dots, n$$

In fatti:

$$\hat{\beta} = \left[\sum_{i=1}^n \begin{pmatrix} x_i & x_i' \\ z_i & z_i \end{pmatrix} \right]^{-1} \sum_{i=1}^n \begin{pmatrix} x_i \\ z_i \end{pmatrix} \left(\frac{y_i}{z_i} \right) = \left(\sum_{i=1}^n \frac{x_i x_i'}{z_i^2} \right)^{-1} \sum_{i=1}^n \left(\frac{x_i y_i}{z_i^2} \right)$$

③ Dati aggregati

X_{ij} = reddito del j -esimo individuo della regione i $j = 1, 2, \dots, n_i$ = numero di individui nella regione i -esima

$i = 1, \dots, N \equiv$ num. regioni.

y_{ij} = consumo j -esimo individuo della regione i

Supponiamo che valga la relazione a livello individuale:

$$y_{ij} = \beta X_{ij} + \varepsilon_{ij}, \quad E[\varepsilon_{ij} | X] = 0$$
$$E[\varepsilon_{ij}^2 | X] = \sigma^2$$
$$E[\varepsilon_{ij} \varepsilon_{kl} | X] = 0, \quad ij \neq lk$$

Il campione osservato è invece costituito da dati aggregati (medi)

$$y_i = \frac{1}{n_i} \sum_{j=1}^{n_i} y_{ij} \quad (\text{consumo medio regione } i)$$

$$x_i = \frac{1}{n_i} \sum_{j=1}^{n_i} X_{ij} \quad (\text{reddito medio regione } i)$$

e costruiamo il modello

$$y_i = \beta x_i + \varepsilon_i, \quad i=1, 2, \dots, N$$

Quali sono le proprietà di ε_i ?

Ovviamente $\varepsilon_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \varepsilon_{ij}$, quindi

$$E[\varepsilon_i | X] = E\left[\frac{1}{n_i} \sum_{j=1}^{n_i} \varepsilon_{ij} | X\right] = \frac{1}{n_i} \sum_{j=1}^{n_i} E[\varepsilon_{ij} | X] = 0$$

$$V[\varepsilon_i | X] = V\left[\frac{1}{n_i} \sum_{j=1}^{n_i} \varepsilon_{ij} | X\right] = \frac{1}{n_i^2} \sum_{j=1}^{n_i} \underbrace{V[\varepsilon_{ij} | X]}_{\sigma^2} = \frac{\sigma^2}{n_i}$$

Quindi, siamo nell'ambito di un modello lineare con errori eteroschedastici

$$E[y_i | X] = \beta x_i$$

$$V[y_i | X] = \sigma_i^2 = \frac{\sigma^2}{n_i}$$

Se conosco le numerosità n_i , $i=1, \dots, N$
posso usare GLS:

$$y_i = \beta x_i + \varepsilon_i \quad (\text{modello di partenza})$$

$$E(\varepsilon_i | X) = 0, \quad V(\varepsilon_i | X) = \sigma_i^2 = \frac{\sigma^2}{n_i}$$

Passo al modello trasformato dividendo per $\sigma_i = \frac{\sigma}{\sqrt{n_i}}$

$$\frac{y_i}{\sigma_i} = \beta \frac{x_i}{\sigma_i} + \varepsilon_i / \sigma_i$$

$$\frac{y_i}{\sqrt{\sigma^2/n_i}} = \beta \frac{x_i}{\sqrt{\sigma^2/n_i}} + \tilde{\varepsilon}_i \quad (\text{modello trasformato})$$

$$\tilde{y}_i = \beta \tilde{x}_i + \tilde{\varepsilon}_i$$

dove $\tilde{y}_i = y_i / \sqrt{\sigma^2/n_i}$ e $\tilde{x}_i = x_i / \sqrt{\sigma^2/n_i}$, $i=1, 2, \dots, N$

Inoltre, $\tilde{\varepsilon}_i$ soddisfa le condizioni del Modello lin. ordinario.

Lo stimatore GLS corrisponde allo stimatore OLS sul modello trasformato:

$$\begin{aligned}\hat{\beta}_{GLS} &= \left(\sum_1^N \tilde{x}_i \tilde{x}_i' \right)^{-1} \sum_1^N \tilde{x}_i \tilde{y}_i \\ &= \left(\sum_1^N x_i^2 / \left(\frac{\sigma^2}{n_i} \right) \right)^{-1} \left(\sum_1^N \frac{x_i y_i}{\left(\frac{\sigma}{\sqrt{n_i}} \right) \left(\frac{\sigma}{\sqrt{n_i}} \right)} \right) = \left(\sum_1^N n_i x_i^2 \right)^{-1} \sum_1^N n_i x_i y_i\end{aligned}$$

che è diverso da $\hat{\beta}_{OLS} = \left(\sum_1^N x_i^2 \right)^{-1} \left(\sum_1^N x_i y_i \right)$.

④ Break strutturale nella varianza

Le varianze di ε_i cambiano in corrispondenza di due punti come osservazione:

$$E[\varepsilon_i^2 | X] = \begin{cases} \sigma_A^2 & \text{se } i = 1, 2, \dots, n^* \\ \sigma_B^2 & \text{se } i = n^* + 1, \dots, n \end{cases}$$

Esempio: great moderation

Se gli errori sono "incorrelati" ($E[\varepsilon_i \varepsilon_j | X] = 0, i \neq j$)
allora:

$$V[\varepsilon | X] = E[\varepsilon \varepsilon' | X] = \begin{bmatrix} \sigma_A^2 & & & \\ & \dots & & \\ & & \sigma_A^2 & \\ & & & \dots & \\ & & & & \sigma_B^2 & \\ & & & & & \dots & \\ & & & & & & \sigma_B^2 \end{bmatrix} \left. \begin{array}{l} \left. \vphantom{\begin{bmatrix} \sigma_A^2 \\ \dots \\ \sigma_A^2 \\ \dots \\ \sigma_B^2 \\ \dots \\ \sigma_B^2 \end{bmatrix}} \right\} n^* \\ \left. \vphantom{\begin{bmatrix} \sigma_A^2 \\ \dots \\ \sigma_A^2 \\ \dots \\ \sigma_B^2 \\ \dots \\ \sigma_B^2 \end{bmatrix}} \right\} n - n^* \end{array} \right.$$

Lo stimatore GLS è:

$$\begin{aligned} \hat{\beta}_{GLS} &= (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} y \\ &= \left(\sum_{i=1}^n \frac{1}{\sigma_i^2} X_i X_i' \right)^{-1} \left(\sum_{i=1}^n \frac{1}{\sigma_i^2} X_i y_i \right), \quad \sigma_i^2 = \begin{cases} \sigma_A^2 & i=1 \dots n^* \\ \sigma_B^2 & i=n^*+1, \dots, n \end{cases} \\ &= \left(\sum_{i=1}^{n^*} \frac{1}{\sigma_A^2} X_i X_i' + \sum_{i=n^*+1}^n \frac{1}{\sigma_B^2} X_i X_i' \right)^{-1} \left(\sum_{i=1}^{n^*} \frac{1}{\sigma_A^2} X_i y_i + \sum_{i=n^*+1}^n \frac{1}{\sigma_B^2} X_i y_i \right) \\ &= \left(\frac{1}{\sigma_A^2} \sum_{i=1}^{n^*} X_i X_i' + \frac{1}{\sigma_B^2} \sum_{i=n^*+1}^n X_i X_i' \right)^{-1} \left(\frac{1}{\sigma_A^2} \sum_{i=1}^{n^*} X_i y_i + \frac{1}{\sigma_B^2} \sum_{i=n^*+1}^n X_i y_i \right) \end{aligned}$$

Lo stimatore non è (ancora) calcolabile: dipende da σ_A^2 e σ_B^2 .

Possiamo stimare σ_A^2 e σ_B^2 usando i residui OLS:

$$\hat{\varepsilon}_i = y_i - x_i' \hat{\beta}_{OLS}, \quad i = 1, 2, \dots, n$$

Come

$$\hat{\sigma}_A^2 = \frac{1}{n^*} \sum_{i=1}^{n^*} \hat{\varepsilon}_i^2 \quad \text{oppure} \quad \frac{1}{n^* - k} \sum_{i=1}^{n^*} \hat{\varepsilon}_i^2$$

$$\hat{\sigma}_B^2 = \frac{1}{n - n^*} \sum_{i=n^*+1}^n \hat{\varepsilon}_i^2 \quad \frac{1}{n - n^* - k} \sum_{i=1}^{n^*} \hat{\varepsilon}_i^2$$

Lo stimatore GLS "feasible" (FGLS) diventa:

$$\hat{\beta}_{FGLS} = \left(\frac{1}{\hat{\sigma}_A^2} \sum x_i x_i' + \frac{1}{\hat{\sigma}_B^2} \sum x_i x_i' \right)^{-1} \left(\frac{1}{\hat{\sigma}_A^2} \sum x_i y_i + \frac{1}{\hat{\sigma}_B^2} \sum x_i y_i \right)$$