

PROBLEMI DI PREVISIONE

Si vuole prevedere il valore di Y_{n+1} per un insieme di valori X osservati.

Supponiamo però per X i valori

$$C = \{1 \quad X_{2,n+1} \quad X_{3,n+1} \quad \dots \quad X_{k,n+1}\}$$

E' possibile fare una previsione puntuale o stimare un intervallo di previsioni.

$$\begin{aligned} Y_{n+1} &= \beta_1 + \beta_2 X_{2,n+1} + \dots + \beta_k X_{k,n+1} + u_{n+1} \\ &= C' \beta + u_{n+1} \end{aligned}$$

$1 \times k$ $k \times 1$ 1×1

$$E[Y_{n+1}] = C'\beta$$

Utilizzando le proprietà BLUE di $\hat{\beta}$ avremo il
PREVISORE PUNTUALE

$$\hat{Y}_{n+1} = C'\hat{\beta} \quad \text{sarà } \underline{\underline{\text{BLUFF}}}$$

APPLICAZIONE

$$Y = \beta_1 + \beta_2 X + u$$

Voglio prevedere Y da X_0 . Per calcolare l'intervallo devo determinare

$$(X'X) = \begin{bmatrix} n & \sum X \\ \sum X & \sum X^2 \end{bmatrix}$$

$$C = \{1 \quad X_0\}$$

$$C'(X'X)^{-1}C = \frac{\sum X^2 - 2X_0 \sum X + u X_0^2}{u \sum X^2 - (\sum X)^2}$$


Infatti

$$\begin{aligned} & \{1 \quad X_0\} \frac{1}{n \sum X^2 - (\sum X)^2} \begin{bmatrix} \sum X^2 & -\sum X \\ -\sum X & n \end{bmatrix} \begin{pmatrix} 1 \\ X_0 \end{pmatrix} = \\ & = \frac{1}{n \sum X^2 - (\sum X)^2} [\sum X^2 - X_0 \sum X, X_0 n - \sum X] \begin{pmatrix} 1 \\ X_0 \end{pmatrix} = \\ & = \frac{(\sum X^2 - X_0 \sum X) + (X_0^2 n - X_0 \sum X)}{n \sum X^2 - (\sum X)^2} = \end{aligned}$$

$$= \frac{\sum X^2 - 2X_0 \sum X + nX_0^2}{n \sum X^2 - (\sum X)^2} = \frac{1}{n} + \frac{(X_0 - \bar{X})^2}{\sum X^2}$$

Lo standard error di Y_0 sarà

$$s.e.(\hat{Y}_0) = s \sqrt{1 + \frac{1}{n} + \frac{(X_0 - \bar{X})^2}{\sum (X_i - \bar{X})^2}}$$



A parità di dati osservati l'intervallo sarà tanto più largo quanto più X_0 è distante da \bar{X}

CENNI SULLE VARIABILI DUMMY

(Variabili di comodo)

Fino ad ora abbiamo assunto che nella equazione

$$\text{generale} \quad Y = X\beta + u$$

Le variabili X siano variabili cardinali date dalla teoria economica.

E' possibile introdurre variabili cosiddette "di comodo" che riescano a rappresentare diversi fattori :

- EFFETTI TEMPORALI
- EFFETTI SPAZIALI
- VARIABILI QUALITATIVE

È possibile che un modello economico possa subire mutamenti strutturali :


FUNZIONE DI CONSUMO

$$C = \alpha_1 + \beta Y + u$$

Tempo di guerra

$$C = \alpha_2 + \beta Y + u$$

Tempo di pace



Si ipotizza comunque che la propensione

marginale al consumo $\frac{\partial C}{\partial Y} = \beta$ rimanga
invariata in entrambi i periodi

Invece di considerare i due modelli separatamente (stime meno precise) vengono uniti in una sola relazione

$$C = \alpha_1 X_1 + \alpha_2 X_2 + \beta Y + u$$

Dove X_1 e X_2 sono variabili dummy :

$$X_1 = \begin{cases} 1 & \text{anni di guerra} \\ 0 & \text{anni di pace} \end{cases}$$

$$X_2 = \begin{cases} 0 & \text{anni di guerra} \\ 1 & \text{anni di pace} \end{cases}$$

La matrice β dei coefficienti sar\`a $\beta = \begin{pmatrix} \alpha_1 \\ \alpha_2 \\ \beta \end{pmatrix}$

e la matrice dei dati

$$X = (X_1 \quad X_2 \quad Y) = \begin{bmatrix} 0 & 1 & Y_1 \\ 0 & 1 & Y_2 \\ \cdot & \cdot & Y_3 \\ 0 & 1 & \cdot \\ 1 & 0 & \cdot \\ 1 & 0 & \cdot \\ \cdot & \cdot & \cdot \\ 1 & 0 & \cdot \\ 0 & 1 & \cdot \\ \cdot & \cdot & \cdot \\ 0 & 1 & Y_n \end{bmatrix}$$

La trappola delle variabili di comodo

Quando utilizziamo le variabili dummy è necessario fare attenzione a come viene costruito il modello, per non rendere la matrice $(X'X)$ singolare.

Infatti se nel modello precedente lasciavamo una intercetta : $C = \alpha_0 + \alpha_1 X_1 + \alpha_2 X_2 + \beta Y + u$

$$X = \begin{bmatrix} 1 & 0 & 1 & Y_1 \\ 1 & 0 & 1 & Y_2 \\ \cdot & \cdot & \cdot & \cdot \\ 1 & 0 & 1 & \cdot \\ 1 & 1 & 0 & \cdot \\ 1 & 1 & 0 & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ 1 & 1 & 0 & \cdot \\ 1 & 0 & 1 & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ 1 & 0 & 1 & Y_n \end{bmatrix}$$

$$1 \times X_0 - 1 \times X_1 - 1 \times X_2 + 0 \times Y = 0$$

Abbiamo che le 4 colonne di X sono linearmente dipendenti $rank(X) = rank(X'X) = 3 \neq k$
 $(X'X)$ non è invertibile

Volendo utilizzare una regressione con intercetta si utilizzerà così solo una dummy :

$$C = \gamma_1 + \gamma_2 X_2 + \beta Y + u$$

$$X_2 = \begin{cases} 0 & \text{anni di guerra} \\ 1 & \text{anni di pace} \end{cases}$$

β = PMC in entrambi i periodi

$\alpha_1 = \gamma_1$ = intercetta anni di guerra

$\alpha_2 = \gamma_1 + \gamma_2$ = intercetta anni di pace

$\alpha_1 - \alpha_2 = \gamma_2$ = differenza tra l'intercetta del periodo guerra e pace

- Cambiamento di coefficiente angolare

$$C = \alpha + \beta_1 Y + (\beta_2 - \beta_1) X_2 Y + u$$

$$X_2 = \begin{cases} 0 & \text{anni di guerra} & C = \alpha + \beta_1 Y + u \\ 1 & \text{anni di pace} & C = \alpha + \beta_2 Y + u \end{cases}$$

$\beta_2 - \beta_1$ = differenza propensione marginale al consumo nei due periodi

$$Y = \beta_1 + \beta_2 SVA + u$$

$Y = \text{km} / \text{litro}$

$SVA = \text{Stima Vita Auto in anni}$

$$\hat{Y} = 7.952 + 0.693 SVA$$

(1.753) (0.061)

$$\bar{R}^2 = 0.74$$

$$Y = \beta_1 + \beta_2 W + \beta_3 \frac{S}{A} + \beta_4 \frac{G}{D} + \beta_5 SVA + u$$

$W = \text{peso in Kg}$

$$\frac{S}{A} = \begin{cases} 0 & \text{cambio standard} \\ 1 & \text{cambio automatico} \end{cases}$$

$$\frac{G}{D} = \begin{cases} 0 & \text{gas} \\ 1 & \text{diesel} \end{cases}$$

$$\hat{Y} = 22.008 - 0.002W - 2.760 \frac{S}{A} + 3.28 \frac{G}{D} + 0.415 SVA$$

(5.349) (0.001) (0.708) (1.413) (0.097)

$$\bar{R}^2 = 0.82$$

MULTICOLLINEARITA'

Quando tra due o più variabili esplicative vi è perfetta collinearità o multicollinearità, la matrice $(X'X)$ non è più a rango pieno e le stime OLS non possono essere calcolate.

Si può però facilmente fare una sostituzione di variabile

Es :

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

$$X_2 = \gamma X_1 + \theta$$

$$Y = \alpha + \beta_1 X_1 + \beta_2 \theta + \beta_2 \gamma X_1 + u$$

$$= \lambda_1 + \lambda_2 X_1 + u$$

$$\lambda_1 = \alpha + \beta_2 \theta$$

$$\lambda_2 = \beta_1 + \gamma \beta_2$$

Il problema della multicollinearità esiste quindi quando due o più regressori sono **quasi-collineari** ovvero quando il coefficiente di correlazione tra i regressori è alto .

•MODELLO A 3 VARIABILI

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

$$Y = \beta_2 X_2 + \beta_3 X_3 + u - \bar{u}$$

$$\hat{\beta} = \begin{pmatrix} \hat{\beta}_2 \\ \hat{\beta}_3 \end{pmatrix} = (X'X)^{-1} X' y$$

$$V(\hat{\beta}) = \sigma^2 (X'X)^{-1} = \frac{\sigma^2}{\sum X_2^2 \sum X_3^2 - (\sum X_2 X_3)^2} \begin{pmatrix} \sum X_3^2 & -\sum X_2 X_3 \\ -\sum X_2 X_3 & \sum X_2^2 \end{pmatrix}$$

$$\begin{aligned}
V(\hat{\beta}_2) &= \frac{\sigma^2 \sum X_3^2}{\sum X_2^2 \sum X_3^2 - (\sum X_2 X_3)^2} = \\
&= \frac{\sigma^2 \sum X_3^2}{\sum X_2^2 \sum X_3^2 \frac{(\sum X_2^2 \sum X_3^2 - (\sum X_2 X_3)^2)}{\sum X_2^2 \sum X_3^2}} \\
&= \frac{\sigma^2}{\sum X_2^2 (1 - r_{23}^2)}
\end{aligned}$$

$$V(\hat{\beta}_3) = \frac{\sigma^2}{\sum X_3^2 (1 - r_{23}^2)}$$

È facile vedere che valori molto alti di r_{23}^2 rendono le stime OLS molto imprecise.

Inoltre piccole variazioni nella matrice dei dati provocano o possono provocare grandi variazioni nella stima dei parametri.

ESEMPIO-APPLICAZIONE: instabilità delle stime

$$Y = \beta_2 X_2 + \beta_3 X_3 + u - \bar{u}$$

$$\begin{array}{ll} \text{Dati : } \sum X_{2i}^2 = 200 & \sum X_{2i} X_{3i} = 150 \\ \sum X_{3i}^2 = 113 & \sum X_{2i} Y_i = 350 \\ & \sum X_{3i} Y_i = 263 \end{array}$$

$$\hat{\beta}_2 = \frac{\sum X_3^2 \sum X_2 Y - \sum X_2 X_3 \sum X_3 Y}{\sum X_2^2 \sum X_3^2 - (\sum X_2 X_3)^2} =$$

$$\frac{113 \times 350 - 150 \times 263}{200 \times 113 - 150^2} = \frac{39550 - 39450}{22600 - 22500} = \frac{100}{100} = 1$$

$$\hat{\beta}_3 = \frac{52600 - 52500}{22600 - 22500} = \frac{100}{100} = 1$$

$$r_{X_2 X_3}^2 = \frac{(\sum X_2 X_3)^2}{\sum X_2^2 \sum X_3^2} = \frac{150^2}{200 \times 113} = 0.995$$

Togliendo solo una osservazione:

$$\sum X_2^2 = 199 \quad \sum X_2 X_3 = 149$$

$$\sum X_3^2 = 112 \quad \sum X_2 Y = 327.5$$

$$\sum X_3 Y = 261.5$$

$$\hat{\beta}_2 = \frac{112 \times 347.5 - 149 \times 261.5}{199 \times 112 - 149^2} = \frac{-43.5}{87} = -\frac{1}{2}$$

$$\hat{\beta}_3 = \frac{199 \times 261.5 - 149 \times 347.5}{199 \times 112 - 149^2} = \frac{261}{87} = 3$$

Si modificano molto le stime

ETEROSCHEDASTICITA'

Avevamo ipotizzato che

$$E[uu'] = \sigma^2 I$$

tale assunzione è in molte situazioni non
valida

dobbiamo quindi riformulare il problema
nella forma

$$E[u] = 0$$

$$E[uu'] = \sigma^2 \Omega$$

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

$$y = X\beta + u$$

$$E[\hat{\beta}] = \beta + (X'X)^{-1} X' E(u) = \beta$$

Sono ancora **corretti** ma **non efficienti** (ovvero non sono necessariamente a varianza minima)

$$\begin{aligned} V(\hat{\beta}) &= (X'X)^{-1} X' E(uu') X (X'X)^{-1} \\ &= (X'X)^{-1} X' \Omega X (X'X)^{-1} \sigma^2 \end{aligned}$$

GOLDFELD – QUANDT TEST

- Si ordinano le osservazioni secondo la variabile X_j che si ipotizza sia la causa dell'eteroschedasticità
- Si divide il campione in tre parti di numerosità n_1 n_2 n_3 .
- Dopo la stima OLS nei tre sottocampioni si calcola $e_1' e_1$ $e_3' e_3$

$$F = \frac{e_1' e_1}{e_3' e_3} \quad F_{n_1-k, n_3-k}$$

Sotto H_0 : omoschedasticità : (il valore di F è piccolo)

$$F_{empirico} > F_{teorico} \Rightarrow \text{Rifiuto } H_0$$

RIMEDI

1. σ_i $i = 1, \dots, n$ siano valori noti.

si applicano i **MINIMI QUADRATI PESATI (WLS)**

ovvero si applica OLS al modello trasformato

$$y_i^* = \frac{y_i}{\sigma_i} \quad ; \quad x_{ij}^* = \frac{x_{ij}}{\sigma_i} \quad ; \quad \varepsilon_i^* = \frac{\varepsilon_i}{\sigma_i}$$

Ovvero
$$y_i^* = \beta_1 x_{i1}^* + \beta_2 x_{i2}^* + \dots + \beta_k x_{ik}^* + \varepsilon_i^*$$

Dove
$$\text{Var}(\varepsilon_i^*) = \text{Var}\left(\frac{\varepsilon_i}{\sigma_i}\right) = \frac{1}{\sigma_i^2} \text{Var}(\varepsilon_i) = \frac{\sigma_i^2}{\sigma_i^2} = 1$$

2. \exists relazione tra la componente stocastica e uno dei regressori

$$y_i = \beta_1 + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \varepsilon_i$$

Es.
$$\text{Var} \varepsilon_i = C x_{i2}^2$$

Trasformiamo il modello

$$y_i^* = \frac{y_i}{x_{i2}} \quad ; \quad x_{ij}^* = \frac{x_{ij}}{x_{i2}} \quad ; \quad \varepsilon_i^* = \frac{\varepsilon_i}{x_{i2}}$$

$$\Rightarrow \frac{y_i}{x_{i2}} = \beta_1 \frac{1}{x_{i2}} + \beta_2 + \dots + \beta_k \frac{x_{ik}}{x_{i2}} + \frac{\varepsilon_i}{x_{i2}}$$

Dove
$$\text{Var}(\varepsilon_i^*) = \text{Var}\left(\frac{\varepsilon_i}{x_{i2}}\right) = \frac{1}{x_{i2}^2} \text{Var}(\varepsilon_i) = C$$

Applico OLS

ESERCIZIO

La stima di un modello lineare sulla base dei valori del Reddito e del Consumo di 30 famiglie americane fornisce i seguenti valori :

$$\hat{C} = 1480 + 0.788y \quad R^2 = 0.97$$

(3.29) (29.37)

La stima dello stesso modello sulle prime 12 e sulle ultime 12 osservazioni fornisce i seguenti valori:

$$\hat{C} = 846.7 + 0.837y \quad R^2 = 0.91$$

(0.74) (9.91)

$$RSS = 1069000$$

$$\hat{C} = 2306.7 + 0.747y \quad R^2 = 0.71$$

(0.79) (5.00)

$$RSS = 3344000$$

Verificare l'ipotesi di presenza di eteroschedasticità ed in caso affermativo indicare la procedura di correzione.

$$F = \frac{3344000}{1069000} = 3.12 \quad F_{10,10} = 1.83$$

C'è presenza di eteroschedasticità