

# Analisi di Regressione Multipla

## Stima OLS della relazione *Test Score/STR* :

$$\widehat{TestScore} = 698.9 - 2.28 \times STR, \quad R^2 = .05, \quad SER = 18.6$$

(10.4) (0.52)

E' una stima credibile dell'effetto causale sul rendimento nei test di un cambio del rapporto studenti-insegnanti?

*No*: ci sono fattori omessi che confondono l'effetto (reddito familiare; se lo studente parla l'inglese come lingua madre) questi rendono le stime OLS distorte: *STR* cattura anche l'effetto dei fattori omessi.

# Analisi di Regressione Multipla

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$$

## 1. Stima

# Similarità con la regressione semplice

- $\beta_0$  è la costante (intercetta della regressione)
- da  $\beta_1$  a  $\beta_k$  sono tutti chiamati coefficienti angolari
- $u$  è l'errore stocastico (o disturbo)
- Abbiamo bisogno dell'assunzione sulla media condizionata pari a zero, ovvero
- $E(u|x_1, x_2, \dots, x_k) = 0$
- Dobbiamo sempre minimizzare la somma dei quadrati dei residui, così avremo  $k+1$  condizioni del primo ordine

# Interpretazione della regressione multipla

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \dots + \hat{\beta}_k x_k, \text{ da cui}$$

$$\Delta \hat{y} = \Delta \hat{\beta}_1 x_1 + \Delta \hat{\beta}_2 x_2 + \dots + \Delta \hat{\beta}_k x_k,$$

perciò mantenendo fisse  $x_2, \dots, x_k$  si ha che

$$\Delta \hat{y} = \Delta \hat{\beta}_1 x_1, \text{ cioè ogni } \beta \text{ ha}$$

una interpretazione *ceteris paribus*

# Interpretazione della regressione multipla

Consideriamo il caso  $k = 2$ , perciò

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2, \text{ quindi}$$

$$\hat{\beta}_1 = \left( \sum \hat{r}_{i1} y_i \right) / \sum \hat{r}_{i1}^2, \text{ dove } \hat{r}_{i1} \text{ sono}$$

i residui della stima della regressione

$$\hat{x}_1 = \hat{\gamma}_0 + \hat{\gamma}_2 \hat{x}_2$$

# Interpretazione della regressione multipla

- L'equazione precedente implica che regredendo  $y$  su  $x_1$  e  $x_2$  otteniamo lo stesso effetto per  $x_1$  che otterremmo regredendo  $y$  su i residui della regressione di  $x_1$  su  $x_2$
- Questo significa che solo la parte di  $x_{i1}$  che è non correlata con  $x_{i2}$  serve a spiegare la  $y_i$  perciò stiamo stimando l'effetto di  $x_1$  su  $y$  dopo aver depurato l'effetto di  $x_2$  su  $x_1$

# Regressione semplice e regressione multipla

Confrontiamo la regressione semplice  $\tilde{y} = \tilde{\beta}_0 + \tilde{\beta}_1 x_1$   
con la regressione multipla  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2$

In genere,  $\tilde{\beta}_1 \neq \hat{\beta}_1$  tranne il caso in cui:

$\hat{\beta}_2 = 0$  (perciò l'effetto parziale di  $x_2$  è *nullo*) O  
 $x_1$  e  $x_2$  non sono correlate nel campione di dati

# Bontà del modello

Possiamo pensare ad ogni osservazione come composta da una parte spiegata, ed una non spiegata,

$y_i = \hat{y}_i + \hat{u}_i$  definiamo:

$\sum (y_i - \bar{y})^2$  somma totale degli scostamenti dalla media al quadrato (SST)

$\sum (\hat{y}_i - \bar{y})^2$  somma spiegata degli scostamenti dalla media al quadrato (SSE)

$\sum \hat{u}_i^2$  somma dei residui al quadrato (SSR)

Quindi  $SST = SSE + SSR$

# Bontà del modello

- ◆ Quanto bene la nostra retta di regressione si adatta ai dati?
- ◆ Possiamo calcolare la proporzione della somma totale degli scarti al quadrato (SST) che è spiegata dal modello, chiamiamo questa misura R-quadro della regressione
- ◆  $R^2 = SSE/SST = 1 - SSR/SST$

# Bontà del modello

Si può pensare a  $R^2$  come uguale al quadrato del coefficiente di correlazione tra il valore osservato  $y_i$  e il valore stimato  $\hat{y}_i$

$$R^2 = \frac{\left(\sum (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})\right)^2}{\left(\sum (y_i - \bar{y})^2\right)\left(\sum (\hat{y}_i - \bar{\hat{y}})^2\right)}$$

# *R*-quadro

- $R^2$  non può mai diminuire quando una nuova variabile indipendente è aggiunta alla regressione, anzi, è molto probabile che crescerà
- Poiché  $R^2$  tende a crescere con il numero di variabili indipendenti incluse, non è una misura adeguata per confrontare diversi modelli di regressione

# Assunzioni per Correttezza

- ◆ Modello di regressione della popolazione è lineare nei parametri:  $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$

Le assunzioni sono quelle della regressione semplice più quella relativa alla non collinearità perfetta tra le variabili indipendenti:

- ◆  $E(u|x_1, x_2, \dots, x_k) = 0$ , implica che tutte le variabili esplicative sono esogene ;
- ◆ Utilizziamo un campione casuale di dimensione  $n$ ,  $\{(x_{i1}, x_{i2}, \dots, x_{ik}, y_i): i=1, 2, \dots, n\}$ , dal modello di popolazione, in modo tale che il modello campionario è  $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + u_i$  ;
- ◆  $X$  e  $u$  hanno quattro momenti, cioè:  
 $E(X^4) < +\infty$  e  $E(u^4) < +\infty$ .
- ◆ Nessuna delle  $x$  è costante, e non esiste una relazione lineare perfetta tra loro (collinearità)

# Troppe o Poche Variabili

- Cosa succede se nel modello di regressione si inseriscono variabili non rilevanti?
- Non c'è effetto sulle stime dei parametri, e le stime OLS restano corrette
- Cosa succede se escludiamo variabili rilevanti?
- Le stime OLS saranno distorte

# Errore per Variabili Rilevanti Omesse

Supponiamo che il modello vero sia

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + u, \text{ ma stimiamo}$$

$$\tilde{y} = \tilde{\beta}_0 + \tilde{\beta}_1 x_1 + u, \text{ quindi}$$

$$\tilde{\beta}_1 = \frac{\sum (x_{i1} - \bar{x}_1) y_i}{\sum (x_{i1} - \bar{x}_1)^2}$$

# Errore per Variabili Rilevanti Omesse

Il modello vero è

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i, \text{ sostituendo}$$

al numeratore si ottiene

$$\sum (x_{i1} - \bar{x}_1)(\beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + u_i) =$$

$$\beta_1 \sum (x_{i1} - \bar{x}_1)^2 + \beta_2 \sum (x_{i1} - \bar{x}_1)x_{i2} + \sum (x_{i1} - \bar{x}_1)u_i$$

# Errore per Variabili Rilevanti Omesse

$$\tilde{\beta} = \beta_1 + \beta_2 \frac{\sum (x_{i1} - \bar{x}_1) x_{i2}}{\sum ((x_{i1} - \bar{x}_1)^2)} + \frac{\sum (x_{i1} - \bar{x}_1) u_i}{\sum ((x_{i1} - \bar{x}_1)^2)}$$

poichè  $E(u_i) = 0$ , prendendo il valore atteso

$$E(\tilde{\beta}_1) = \beta_1 + \beta_2 \frac{\sum (x_{i1} - \bar{x}_1) x_{i2}}{\sum ((x_{i1} - \bar{x}_1)^2)}$$

# Errore per Variabili Rilevanti Omesse

Consideriamo la regressione di  $x_2$  su  $x_1$

$$\tilde{x}_2 = \tilde{\delta}_0 + \tilde{\delta}_1 x_1 \quad \text{da cui} \quad \tilde{\delta}_1 = \frac{\sum (x_{i1} - \bar{x}_1) x_{i2}}{\sum ((x_{i1} - \bar{x}_1)^2)}$$

$$\text{quindi } E(\tilde{\beta}_1) = \beta_1 + \beta_2 \tilde{\delta}_1$$

# Sintesi sulla Direzione dell' Errore

	$\text{Corr}(x_1, x_2) > 0$	$\text{Corr}(x_1, x_2) < 0$
$\beta_2 > 0$	errore positivo	errore negativo
$\beta_2 < 0$	errore negativo	errore positivo

# Sintesi sull' Errore dovuto a Variabili rilevanti Omesse

- Due casi in cui l' errore è uguale a zero  
 $\beta_2 = 0$ , cioè  $x_2$  non appartiene al modello

*e/o*  $x_1$  e  $x_2$  non sono correlate nel campione.

- Se la correlazione tra  $x_2$ ,  $x_1$  e  $x_2$ ,  $y$  è nella stessa direzione, l' errore sarà positivo
- Se la correlazione tra  $x_2$ ,  $x_1$  e  $x_2$ ,  $y$  è in direzione opposto, l' errore sarà negativo

# Il Caso Generale

- Tecnicamente, possiamo stabilire il segno dell' errore solo nel caso generale che tutte le variabili  $x$  sono non correlate
- Assumiamo che le variabili  $x$  non sono correlate

# Varianza degli stimatori OLS

- ◆ Sappiamo che la distribuzione della nostra stima è centrata intorno al valore vero del parametro.
- ◆ Quanto dispersa è questa distribuzione?
- ◆ Misuriamo la dispersione con la varianza della distribuzione,
- ◆ Assumendo  $\text{Var}(u|x_1, x_2, \dots, x_k) = \sigma^2$   
(Omoschedasticità)

# Varianza degli stimatori OLS

- Sia  $\mathbf{x}$  un vettore di variabili  $(x_1, x_2, \dots, x_k)$
- Assumiamo che  $\text{Var}(u|\mathbf{x}) = \sigma^2$  che implica  $\text{Var}(y|\mathbf{x}) = \sigma^2$
- Le 4 assunzioni di correttezza, più quella di omoschedasticità sono conosciute come assunzioni di Gauss-Markov

# Varianza degli stimatori OLS

Date le assunzioni Gauss-Markov

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{SST_j (1 - R_j^2)}, \text{ dove}$$

$$SST_j = \sum (x_{ij} - \bar{x}_j)^2 \text{ e } R_j^2 \text{ è } R^2$$

della regressione di  $x_j$  su tutte le altre  $x$

# Componenti della Varianza degli stimatori OLS

- La varianza degli errori: una misura grande di  $\sigma^2$  implica una varianza grande degli stimatori OLS
- La varianza campionaria complessiva della variabile  $j$ : una più grande  $SST_j$  implica una varianza degli stimatori OLS più piccola
- Relazione lineare tra le variabili indipendenti: un valore più grande di  $R_j^2$  implica una maggiore varianza degli stimatori OLS

# Modelli di Regressione non Correttamente Specificati

Consideriamo un modello non correttamente specificato

$$y = \tilde{\beta}_0 + \tilde{\beta}_1 x_1, \text{ tale che } Var(\tilde{\beta}_1) = \frac{\sigma^2}{SST_1}$$

Perciò,  $Var(\tilde{\beta}_1) < Var(\hat{\beta}_1)$  tranne il caso in cui

$x_1$  e  $x_2$  non sono correlate,

# Modelli di Regressione non Correttamente Specificati

- Mentre la varianza dello stimatore del modello non correttamente specificato è minore del modello corretto, tranne il caso in cui  $\beta_2 = 0$  lo stimatore del modello non correttamente specificato è distorto
- All' aumentare della dimensione campionaria, la varianza per ogni stimatore converge a zero, e la differenza delle varianze diventa meno importante

# Stima della Varianza dell' Errore

- ◆ Non conosciamo la varianza dell' errore,  $\sigma^2$ , perché non osserviamo l' errore,  $u_i$
- ◆ Cosa osserviamo è il residuo,  $\hat{u}_i$
- ◆ Possiamo utilizzare i residui per stimare la varianza dell' errore

# Stima della Varianza dell' Errore

$$\hat{\sigma}^2 = \left( \sum \hat{u}_i^2 \right) / (n - k - 1) \equiv SSR / df$$

perciò,  $se(\hat{\beta}_j) = \hat{\sigma} / [SST_j (1 - R_j^2)]^{1/2}$

- $df = n - (k + 1)$ , or  $df = n - k - 1$
- $df$  (“degrees of freedom”, gradi di libertà) pari al numero di osservazioni – numero di parametri

# Il Teorema Gauss-Markov

- Date le 5 assunzioni Gauss-Markov si può dimostrare che lo stimatore OLS è “BLUE”
- *Best*
- *Linear*
- *Unbiased*
- *Estimator*
- Perciò, se le assunzioni sono valide, usa lo stimatore OLS