

REGRESSIONE

Molti problemi dell'ingegneria sono collegati alla determinazione delle relazioni tra due o più insiemi di variabili.

Y : variabile di risposta (v. dipendente)

x_1, \dots, x_k : variabili di ingresso (variabili indipendenti)

È ragionevole supporre che per opportune costanti

β_k $k=1, \dots, k$ possa valere

$$Y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k.$$

Tuttavia questo livello di precisione nella pratica non è raggiungibile (è una relazione deterministica)

La relazione viene trasformata in:

$$Y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon \quad (1)$$

ε = errore casuale, $\bar{\varepsilon}$ una v.c. con

$$E(\varepsilon) = 0, \quad \text{var}[\varepsilon] = \sigma^2 \text{ (costante)}$$

σ^2 = varianza dell'errore, riflette la variabilità dell'errore sperimentale.

La relazione (1) può essere scritta nella forma equivalente

$$\mu_{Y|x} = E[Y|x] = \beta_0 + \beta_1 x_1 + \dots + \beta_r x_r \quad (2)$$

con $x = (x_1, \dots, x_r)$.

Se $x \neq 1 \Rightarrow$ REGRESSIONE LINEARE MULTIPLA


$(\beta_0, \dots, \beta_r)$:= coefficienti di regressione,

Se $x = 1 \Rightarrow$ REGRESSIONE LINEARE SEMPLICE e (1), (2):

$$Y = \alpha + \beta x + \varepsilon \quad \sigma \quad E[Y|x] = \alpha + \beta x$$

Le equazioni (1), (2) sono dette equazioni di regressione lineare.

Nel caso $r=1$



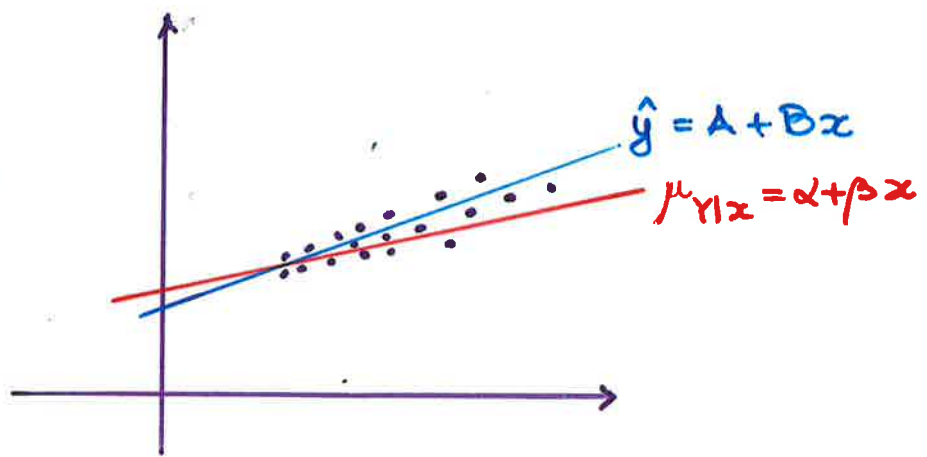
STIMA DEI COEFFICIENTI α, β

Problema: stimare i coefficienti di regressione α, β attraverso i dati.

Supponiamo che A, B siano gli stimatori di α, β .

$$\Rightarrow \hat{y} = A + Bx \quad \text{retta di regressione stimata}$$

Per una grande quantità di dati ci si aspetta che la retta di regressione stimata \hat{y} sia più vicina alle "vera" rette di regressione $\mu_{Y|x} = \alpha + \beta x$.



Al variare di x_i per $i=1, \dots, m$ $Y_i = \alpha + \beta x_i + \epsilon_i$
 con $E[Y_i] = \alpha + \beta x_i$ si ha

$$y_i - E[Y_i] = \epsilon_i.$$

METODO DI STIMA

È fondamentale introdurre il concetto di **RESIDUO**.

Un residuo è essenzialmente un errore nella stima del modello $\hat{y} = A + Bx$.

RESIDUO = ERRORE DI STIMA

Dati (x_i, y_i) $i=1, \dots, m$ e un modello stimato $\hat{y}_i = A + Bx_i$
 il residuo i -esimo e_i è definito da:

$$e_i = y_i - \hat{y}_i, \quad i=1, \dots, m.$$


ovvero

$$y_i = A + Bx_i + e_i$$

N.B.:

e_i : residui (osservati)

ϵ_i : errori del modello concettuale (non osservati).



I valori A, B quali stime di α, β devono essere tali che la **somma dei quadrati dei residui sia minima**.
(somma dei quadrati delle differenze tra predizione e valore osservato).

$$SS_R = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - A - Bx_i)^2$$

METODO DEI MINIMI QUADRATI

Derivando SS_R rispetto ad A e a B si ottengono le seguenti relazioni.

$$\begin{cases} \frac{\partial}{\partial A} SS_R = -2 \sum_{i=1}^n (y_i - A - Bx_i) \\ \frac{\partial}{\partial B} SS_R = -2 \sum_{i=1}^n x_i (y_i - A - Bx_i) \end{cases} \quad (3)$$

(A, B) pti di stazionarietà del sistema (3).

$$\begin{cases} \frac{\partial}{\partial A} SS_R = 0 \\ \frac{\partial}{\partial B} SS_R = 0 \end{cases}$$

da cui si ottengono:

$$\begin{cases} \sum_{i=1}^m y_i = mA + B \sum_{i=1}^m x_i \\ \sum_{i=1}^m x_i y_i = A \sum_{i=1}^m x_i + B \sum_{i=1}^m x_i^2 \end{cases}$$

EQUAZIONI NORMALI

Poniamo $\bar{y} = \frac{1}{m} \sum_{i=1}^m y_i$ e $\bar{x} = \frac{1}{m} \sum_{i=1}^m x_i$

$\Rightarrow m\bar{y} = mA + mB\bar{x} \Rightarrow A = \bar{y} - B\bar{x}$ stimatore di α .

$$\begin{aligned} \sum_{i=1}^m x_i y_i &= mA\bar{x} + B \sum_{i=1}^m x_i^2 \\ &= m\bar{x}(\bar{y} - B\bar{x}) + B \sum_{i=1}^m x_i^2 \\ &= m\bar{x}\bar{y} + B \left[\sum_{i=1}^m x_i^2 - m\bar{x}^2 \right] \end{aligned}$$

$\Rightarrow B = \frac{\sum_{i=1}^m x_i y_i - m\bar{x}\bar{y}}{\sum_{i=1}^m x_i^2 - m\bar{x}^2}$ stimatore di β .

Alternativamente

$$\begin{cases} A = \frac{1}{m} \sum_{i=1}^m y_i - B\bar{x} \\ B = \frac{\sum_{i=1}^m x_i y_i - m\bar{x} \cdot \frac{1}{m} \sum_{i=1}^m y_i}{\sum_{i=1}^m x_i^2 - m\bar{x}^2} = \frac{\sum_{i=1}^m (x_i - \bar{x}) y_i}{\sum_{i=1}^m x_i^2 - m\bar{x}^2} \end{cases}$$

Questo metodo è stato utilizzato per stimare una retta (\hat{y}) la cui peculiarità è quella di essere "vicina" alle coppie (x_i, y_i) di dati osservati.

Osservazione: la stima ai minimi quadrati determina una retta che minimizza la somma dei quadrati degli **sostamenti verticali** dei punti rispetto alla retta.

PROPRIETA' DEGLI STIMATORI

A, B sono stimatori **CORRETTI** di α, β .

Infatti:

$$E[B] = \frac{\sum_{i=1}^n (x_i - \bar{x}) E[y_i]}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}$$
$$= \frac{\sum_{i=1}^n (x_i - \bar{x}) (\alpha + \beta x_i)}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}$$

$$\text{ma } \sum_{i=1}^n (x_i - \bar{x}) = \sum_{i=1}^n x_i - n\bar{x} \equiv 0 \Rightarrow$$

$$E[B] = \frac{\beta \left(\sum_{i=1}^n x_i^2 - \bar{x} \sum_{i=1}^n x_i \right)}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \equiv \beta$$

$$E[A] = \frac{1}{n} \sum_{i=1}^n E[y_i] - E[B] \bar{x}$$

$$= \frac{1}{n} \sum_{i=1}^n (\alpha + \beta x_i) - \beta \bar{x}$$

$$= \frac{1}{n} \sum_{i=1}^n \alpha + \beta \cdot \frac{1}{n} \sum_{i=1}^n x_i - \beta \bar{x}$$

$$= \frac{1}{n} \cdot n\alpha \equiv \alpha$$

Si può provare che

$$\text{var}[B] = \frac{\sigma^2}{\sum_{i=1}^m x_i^2 - m\bar{x}^2}, \quad \text{var}[A] = \frac{\sigma^2 \sum_{i=1}^m x_i^2}{m(\sum_{i=1}^m x_i^2 - n\bar{x}^2)}$$

Ipotesi : le variabili y_i sono

- indipendenti
- normali
- con medie $E[y_i] = \alpha + \beta z_i$
- con varianza σ^2

⇒ A, B sono v.c. **NORMALI** (perché combinazioni lineari di v.c. normali).

STIMA DI σ^2

La quantità SS_R può essere usata per stimare la varianza σ^2 degli errori casuali.

Una stima **CORRETTA** di σ^2 è :

$$s^2 = \frac{SS_R}{m-2}$$

cioè si può dimostrare che

$$E[s^2] \equiv \sigma^2.$$

Notazioni sintetiche :

$$S_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}$$

$$S_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - n \bar{x}^2$$

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

allora si ha:

$$\left\{ \begin{array}{l} A = \bar{y} - B \bar{x} \\ B = \frac{S_{xy}}{S_{xx}} \\ SS_R = \frac{S_{xx} S_{yy} - S_{xy}^2}{S_{xx}} \end{array} \right.$$