

Siano X e Y due v.a. a valori discreti in \mathbb{R} . Per ogni $a, b \in \mathbb{R}$ consideriamo la v.e. $Y - aX - b$. IP momento di ordine due della variabile aleatoria $Y - aX - b$ è

$$E[(Y - aX - b)^2].$$

Si tratta di una funzione che dipende da a e b , cioè

$$\mathbb{R}^2 \ni (a, b) \mapsto E[(Y - aX - b)^2] \in \mathbb{R}$$

è una funzione da \mathbb{R}^2 in \mathbb{R} .

Il problema che vogliamo risolvere è il seguente:

"determinare, se esiste, $(\bar{a}, \bar{b}) \in \mathbb{R}^2$ t.c.

$$\min_{(a, b) \in \mathbb{R}^2} E[(Y - aX - b)^2] = E[(Y - \bar{a}X - \bar{b})^2] "$$

Se la coppia $(\bar{a}, \bar{b}) \in \mathbb{R}^2$ che soddisfa il problema precedente esiste chiameremo $Y = \bar{a}X + \bar{b}$ retta di regressione.

Si tratta di risolvere un problema di minimo libero.

Lo vogliamo risolvere mettendo in evidenza la speranza matematica e le varianze rispettivamente di X e Y .

Per questa ragione scriviamo la funzione $E[(Y - aX - b)^2]$ mettendo in evidenza le precedenti grandezze.

Quindi

$$E[(y - ax - b)^2] = E\left[\underbrace{(y - E[y] - a(x - E[x]))}_{\text{Somma zero}} + \underbrace{E[y] - aE[x] - b}_{\text{Somma zero}}\right]^2$$
$$= E\left[(y - E[y])^2 + a^2(x - E[x])^2 + B^2 - 2(y - E[y])a(x - E[x]) + 2(y - E[y])B - 2a(x - E[x])B\right],$$

dove $B = E[y] - aE[x] - b$; quindi per la linearità di E risulta:

$$E[(y - ax - b)^2] = E[(y - E[y])^2] + E[a^2(x - E[x])^2] + E[B^2] - 2E[(y - E[y])a(x - E[x])] + 2E[(y - E[y])B] - 2E[a(x - E[x])B]$$
$$= \text{Var}(y) + a^2 \text{Var}(x) + B^2 - 2aE[(y - E[y])(x - E[x])] + 2BE[(y - E[y])] - 2aBE[(x - E[x])]$$
$$= \text{Var}(y) + a^2 \text{Var}(x) + B^2 - 2a \text{Cov}(x, y);$$

perché $E[(y - E[y])(x - E[x])] = E[xy - E[y]x - E[x]y + E[x]E[y]]$

$$= E[xy] - E[y]E[x] - E[x]E[y] + E[x]E[y]$$
$$= E[xy] - E[x]E[y] \stackrel{\text{def}}{=} \text{Cov}(x, y), \text{ inoltre.}$$
$$E[(y - E[y])] = E[y] - E[y] = 0 \quad \text{e} \quad E[(x - E[x])] = E[x] - E[x] = 0$$

Troviamo i punti critici della funzione

$$(a, b) \xrightarrow{f} \text{Var}(y) + a^2 \text{Var}(x) + (E[y] - aE[x] - b)^2 - 2a \text{Cov}(x, y)$$

↑ numero ↑ numero ↑ numero ↓ numero

$\nabla f(a,b) = \left(\frac{\partial f(a,b)}{\partial a}, \frac{\partial f(a,b)}{\partial b} \right)$. I punti critici sono soluzioni di

$$\begin{cases} \frac{\partial f(a,b)}{\partial a} = 0 \\ \frac{\partial f(a,b)}{\partial b} = 0 \end{cases} \iff \begin{cases} 2a \operatorname{Var}(X) - 2E[X](E[Y] - aE[X] - b) - 2\operatorname{Cov}(X,Y) = 0 \\ -2(E[Y] - aE[X] - b) = 0 \end{cases}$$

$$\iff \begin{cases} 2a \operatorname{Var}(X) - 2\operatorname{Cov}(X,Y) = 0 \\ b = E[Y] - aE[X] \end{cases} \iff \begin{cases} a = \frac{\operatorname{Cov}(X,Y)}{\operatorname{Var}(X)} \\ b = E[Y] - \frac{\operatorname{Cov}(X,Y)}{\operatorname{Var}(X)} E[X] \end{cases}$$

In questo caso occorre supporre $\operatorname{Var}(X) \neq 0$.

Calcoliamo anche la matrice Hessiana di f

$$H_f(a,b) = \begin{bmatrix} \frac{\partial^2 f(a,b)}{\partial a^2} & \frac{\partial^2 f(a,b)}{\partial a \partial b} \\ \frac{\partial^2 f(a,b)}{\partial a \partial b} & \frac{\partial^2 f(a,b)}{\partial b^2} \end{bmatrix} = \begin{bmatrix} 2\operatorname{Var}(X) + 2(E[X])^2 & 2E[X] \\ 2E[X] & 2 \end{bmatrix}$$

Calcoliamo gli autovalori

$$\det(H_f(a,b) - \lambda I) = 0 \iff \det \begin{pmatrix} 2\operatorname{Var}(X) + 2(E[X])^2 - \lambda & 2E[X] \\ 2E[X] & 2 - \lambda \end{pmatrix} = 0$$

$$\iff (2\operatorname{Var}(X) + 2(E[X])^2 - \lambda)(2 - \lambda) - 4(E[X])^2 = 0 \iff$$

$$4\operatorname{Var}(X) + 4(E[X])^2 - 2\lambda - 2\lambda \operatorname{Var}(X) - 2\lambda(E[X])^2 + \lambda^2 - 4(E[X])^2 = 0 \iff$$

$$\lambda^2 - 2(1 + \operatorname{Var}(X) + E[X]^2)\lambda + 4\operatorname{Var}(X) = 0$$

$$\begin{aligned} \frac{\Delta}{4} &= (1 + \operatorname{Var}(X) + E[X]^2)^2 - 4\operatorname{Var}(X) \\ &= 1 + \operatorname{Var}(X)^2 + E[X]^4 + 2\operatorname{Var}(X) + 2E[X]^2 + 2\operatorname{Var}(X)E[X]^2 - 4\operatorname{Var}(X) \end{aligned}$$

$$= 1 + \text{Var}(x)^2 + E[x]^4 - 2\text{Var}(x) + 2E[x]^2 + 2\text{Var}(x)E[x]^2$$

↓ ho effettuato una minorazione.

$$\geq 1 + \text{Var}(x)^2 + E[x]^4 - 2\text{Var}(x) - 2E[x]^2 + 2\text{Var}(x)E[x]^2$$

$$= \left(1 - \text{Var}(x) - E[x]^2\right)^2 \geq 0. \text{ Quindi le radici sono entrambe reali. Inoltre,}$$

$$\lambda_1 = 1 + \text{Var}(x) + E[x]^2 + \sqrt{\frac{\Delta}{4}} > 0 \quad e$$

$$\lambda_2 = 1 + \text{Var}(x) + E[x]^2 - \sqrt{\frac{\Delta}{4}} > 1 + \text{Var}(x) + E[x]^2 - \sqrt{(1 + \text{Var}(x) + E[x]^2)^2} \geq 0$$

Ovvero entrambi gli autovalori sono positivi.

Pertanto la funzione è convessa e in $\left(\frac{\text{Cov}(X,Y)}{\text{Var}(X)}, E[Y] - \frac{\text{Cov}(X,Y)}{\text{Var}(X)}E[X]\right)$

f realizza un minimo assoluto, cioè per

$$(\bar{a}, \bar{b}) = \left(\frac{\text{Cov}(X,Y)}{\text{Var}(X)}, E[Y] - \frac{\text{Cov}(X,Y)}{\text{Var}(X)}E[X]\right) \text{ si ha}$$

$$\min_{(a,b) \in \mathbb{R}^2} E[(Y - aX - b)^2] = E[(Y - \bar{a}X - \bar{b})^2]$$

e la retta di regressione è quindi:

$$y = \bar{a}x + \bar{b}.$$

Domanda: come si poteva concludere più rapidamente che $H_f(a,b)$ è semi-definita positiva per ogni $(a,b) \in \mathbb{R}^2$?

Domanda: anche calcolando direttamente gli autovalori come si poteva concludere che entrambi gli autovalori sono positivi o nulli senza scrivere la formula risolutiva?