

Una muestra de n obsn. multivar. es el conjunto de mediciones de ' p ' variables distintas en el mismo sujeto o ensayo. Si se obtienen ' n ' observaciones, los datos se resumen en la matriz

$$X_{(n \times p)} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{np} \end{bmatrix} \leftarrow \text{los } n \text{ obs. con } p \text{ componentes}$$

1) Representación geométrica de la muestra:


Re-escribamos X así: $X_{(n \times p)} = [\underline{x}_1 | \underline{x}_2 | \dots | \underline{x}_p]$, donde

$\underline{x}_i' = [x_{1i} \ x_{2i} \ \dots \ x_{ni}]$ son las ' n ' mediciones hechas para los ' n ' individuos, respecto de la ' i '-ésima variable

Apartado: La proyección (o sombra) del vector $\underline{x}$ sobre el vector $\underline{y}$

es: $\frac{(\underline{x}'\underline{y})}{\underline{y}'\underline{y}} \underline{y} = \frac{(\underline{x}'\underline{y})}{L_y} \frac{1}{L_y} \underline{y}$, donde $L_y = \sqrt{\underline{y}'\underline{y}}$


$\cos(\theta) = \frac{\underline{x}'\underline{y}}{L_x L_y}$
(ver p. 53 cap. 2)



$L_x = \sqrt{\underline{x}'\underline{x}}$

Consideren el vector $\frac{1}{\sqrt{n}} \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}_{(n \times 1)} = \frac{1}{\sqrt{n}} \cdot \mathbf{1}$. Entonces, ⁽²⁾

$L_{\frac{1}{\sqrt{n}} \cdot \mathbf{1}} = 1$. La proyección del vector $\underline{y}_i$ en el vector unitario $\left(\frac{1}{\sqrt{n}}\right) \mathbf{1}$ es igual a: $\underline{y}_i' \left(\frac{1}{\sqrt{n}} \mathbf{1}\right) \cdot \frac{1}{\sqrt{n}} \mathbf{1}$, y $\underline{y}_i' \left(\frac{1}{\sqrt{n}} \mathbf{1}\right) \frac{1}{\sqrt{n}} \mathbf{1} = \frac{x_{1i} + x_{2i} + \dots + x_{ni}}{n} \cdot \mathbf{1} = \bar{x}_i \mathbf{1}$. Esto es, la media en la muestra de la variable ' i ' ($\bar{x}_i = \frac{\underline{y}_i' \mathbf{1}}{n}$), es la cantidad por la cual hay que multiplicar el vector $\mathbf{1}$ para obtener la proyección de $\underline{y}_i$ sobre la línea determinada por $\mathbf{1}$:



Entonces, $\underline{d}_i = \begin{bmatrix} x_{1i} - \bar{x}_i \\ x_{2i} - \bar{x}_i \\ \vdots \\ x_{ni} - \bar{x}_i \end{bmatrix}$ es entonces el vector que contiene las desviaciones de la media $\bar{x}_i$ para cada observación, para la variable ' i '.

La varianza de la muestra para la variable 'i' es proporcional al (3)
 (largo)² de $\underline{d_i}$: $(L_{\underline{d_i}})^2 = \underline{d_i}' \underline{d_i} = \sum_{j=1}^m (x_{ji} - \bar{x}_i)^2$ ec. (*)

Así mismo, el largo de dichas desviaciones es proporcional a la desviación estándar de la muestra (para la variable 'i').

Para dos vectores de desviaciones $\underline{d_i}$ y $\underline{d_k}$,

$$\underline{d_i}' \underline{d_k} = \sum_{j=1}^m (x_{ji} - \bar{x}_i)(x_{jk} - \bar{x}_k) \quad \text{ec. (**)}$$

Si θ_{ik} denota el ángulo entre $\underline{d_i}$ y $\underline{d_k}$, entonces

$$\underline{d_i}' \underline{d_k} = L_{\underline{d_i}} L_{\underline{d_k}} \cos(\theta_{ik}) \quad , \quad \text{y usando las ecs. (*) y (**):}$$

$$\underbrace{\sum_{j=1}^m (x_{ji} - \bar{x}_i)(x_{jk} - \bar{x}_k)}_{= S_{ik}} = \underbrace{\sqrt{\sum_{j=1}^m (x_{ji} - \bar{x}_i)^2}}_{\sqrt{S_{ii}}} \underbrace{\sqrt{\sum_{j=1}^m (x_{jk} - \bar{x}_k)^2}}_{\sqrt{S_{kk}}} \times \cos(\theta_{ik})$$

Por lo que:

$$\cos(\theta_{ik}) = \frac{S_{ik}}{\sqrt{S_{ii}} \sqrt{S_{kk}}} = R_{ik} //$$

El coseno del ángulo entre $\underline{d_i}$ y $\underline{d_k}$ es la correlación entre la muestra 'i' y 'k'. Entonces, si dos vectores desviación tienen casi la misma orientación (i.e. $\theta_{ik} \approx 0$), entonces la correlación va a ser casi 1. Si dos vectores son perpendiculares, la correlación de la muestra será 0 y si están orientados de manera opuesta, -1.

2) Muestra aleatoria y momentos de la muestra.

(4)

Antes del muestreo, asumimos que cada uno de los vectores $\underline{X}_j$ que tendrá mediciones en 'p' variables es un vector aleatorio, y que juntos, los 'n' vectores conforman una matriz aleatoria:

$$X_{(n \times p)} = \begin{bmatrix} \underline{X}'_1 \\ \underline{X}'_2 \\ \vdots \\ \underline{X}'_n \end{bmatrix} \quad \text{eq (***)}$$

Def.: Muestra aleatoria: Si los vectores $\underline{X}'_1, \underline{X}'_2, \dots, \underline{X}'_n$ en (***) representan observaciones independientes de una misma distribución conjunta con densidad $f(\underline{X}) = f(x_1, x_2, \dots, x_p)$, entonces se dice que $\underline{X}_1, \underline{X}_2, \dots, \underline{X}_n$ forman una muestra aleatoria de $f(\underline{X})$. La distribución conjunta de la muestra está dada por

$$f(\underline{X}_1) f(\underline{X}_2) \dots f(\underline{X}_n), \text{ donde } f(\underline{X}_j) = f(x_{j1}, x_{j2}, \dots, x_{jp}).$$

Resultado 2.1: Sea $\underline{X}_1, \underline{X}_2, \dots, \underline{X}_n$ una muestra aleatoria de una distribución conjunta con vector media $\underline{\mu}$ y matriz de var-cov. Σ . Entonces $\bar{\underline{X}}$ es un vector estimador insesgado de $\underline{\mu}$ y su matriz de var-cov es $\frac{1}{n} \Sigma$. Además, $\frac{n}{n-1} S_m$ es un estimador insesgado de Σ , i.e.:

$$E\left[\left(\frac{n}{n-1}\right) S_m\right] = \Sigma$$

Demo/ $E(\bar{X}) = E\left(\frac{1}{n} \underline{X}_1 + \frac{1}{n} \underline{X}_2 + \dots + \frac{1}{n} \underline{X}_n\right)$ (5)

$$= \frac{1}{n} E \underline{X}_1 + \dots + \frac{1}{n} E \underline{X}_n = \sum_{j=1}^n \frac{1}{n} E(\underline{X}_j)$$

$$\stackrel{iid}{=} \frac{1}{n} n \cdot \mu = \mu //$$

Ahora bien:

$$(\bar{X} - \mu)(\bar{X} - \mu)' = \left(\frac{1}{n} \sum_{j=1}^n (\underline{X}_j - \mu)\right) \left(\frac{1}{n} \sum_{l=1}^n (\underline{X}_l - \mu)\right)'$$

(¿Porque?) $\rightarrow$ $= \frac{1}{n^2} \sum_{j=1}^n \sum_{l=1}^n (\underline{X}_j - \mu)(\underline{X}_l - \mu)'$
¡chequemos!

Entonces $E\left[(\bar{X} - \mu)(\bar{X} - \mu)'\right] = \frac{1}{n^2} \sum_{j=1}^n \sum_{l=1}^n E\left[(\underline{X}_j - \mu)(\underline{X}_l - \mu)'\right]$.
 (ec. 4)

Para todo $j \neq l$, $E[(\underline{X}_j - \mu)(\underline{X}_l - \mu)'] = 0$ (¿Porque?),

entonces $Cov(\bar{X}) = E\left[(\bar{X} - \mu)(\bar{X} - \mu)'\right] \stackrel{(ec. 4)}{=} \frac{1}{n^2} \sum_{j=1}^n E[(\underline{X}_j - \mu)(\underline{X}_j - \mu)']$

$$\stackrel{\underline{X}_j iid}{=} \frac{1}{n^2} \cdot n \cdot \Sigma = \frac{1}{n} \Sigma.$$

(6)

Ahora calculemos $E[S_m]$. Para esto, notemos que:

$$\begin{aligned} \sum_{j=1}^m (\underline{X}_j - \underline{\bar{X}})(\underline{X}_j - \underline{\bar{X}})' &= \sum_{j=1}^m (\underline{X}_j - \underline{\bar{X}})\underline{X}_j' + \left(\sum_{j=1}^m (\underline{X}_j - \underline{\bar{X}}) \right) (-\underline{\bar{X}})' \\ &= \sum_{j=1}^m \underline{X}_j \underline{X}_j' - \sum_{j=1}^m \underline{\bar{X}} \underline{X}_j' \\ &= \sum_{j=1}^m \underline{X}_j \underline{X}_j' - \underline{\bar{X}} \sum_{j=1}^m \underline{X}_j' \\ &= \sum_{j=1}^m \underline{X}_j \underline{X}_j' - \underline{\bar{X}} m \underline{\bar{X}}' = \sum_{j=1}^m \underline{X}_j \underline{X}_j' - m \underline{\bar{X}} \underline{\bar{X}}' \end{aligned}$$

$$\therefore E\left[\sum_{j=1}^m (\underline{X}_j - \underline{\bar{X}})(\underline{X}_j - \underline{\bar{X}})'\right] = \sum_{j=1}^m E(\underline{X}_j \underline{X}_j') - m E(\underline{\bar{X}} \underline{\bar{X}}') \quad (\text{ec. } \boxtimes)$$

Ahora bien, para todo vector aleatorio $\underline{V}$ con media y varianza

$\underline{\mu}_V$ y $\underline{\Sigma}_V$ respectivamente, $E(\underline{V} \underline{V}') = \underline{\Sigma}_V + \underline{\mu}_V \underline{\mu}_V'$, por lo tanto:

$$\begin{aligned} \text{L.D. de ec. } \boxtimes &= \sum_{j=1}^m (\underline{\Sigma} + \underline{\mu} \underline{\mu}') - m \left[\frac{1}{m} \underline{\Sigma} + \underline{\mu} \underline{\mu}' \right] \\ &\stackrel{\substack{\uparrow \\ \text{(lado derecho)}}}{\underline{X}_j \text{ iid}} = m \underline{\Sigma} + m \underline{\mu} \underline{\mu}' - \underline{\Sigma} - m \underline{\mu} \underline{\mu}' \\ &= (m-1) \underline{\Sigma}. \quad \text{Como } S_m = \frac{1}{m} \left(\sum_{j=1}^m \underline{X}_j \underline{X}_j' - m \underline{\bar{X}} \underline{\bar{X}}' \right) \end{aligned}$$

resulta que

$$E(S_m) = \frac{(m-1)}{m} \underline{\Sigma}$$

□

Matriz Var-Cov (insurgada):

(7)

$$S = \left(\frac{n}{n-1} \right) S_n = \frac{1}{n-1} \sum_{j=1}^n (\underline{X}_j - \bar{\underline{X}})(\underline{X}_j - \bar{\underline{X}})'$$

En lo que queda del curso, S reemplazará a S_n en la mayoría de las pruebas estadísticas que veremos.

3) Varianza Generalizada:


Con una sola variable, la varianza de la muestra es suficiente para describir la variabilidad en los datos. Cuando se observan p variables, se puede representar la variabilidad total de la muestra con un sólo número: el determinante de S . A este se le llama "Varianza generalizada".

3.1 Varianza generalizada cuando $p=2$:

Sea $S = \begin{bmatrix} S_{11} & S_{12} \\ S_{12} & S_{22} \end{bmatrix}$

$$\text{y } \begin{cases} \underline{d}_1 = \underline{x}_1 - \bar{x}_1 \underline{1}, \underline{d}_2 = \underline{x}_2 - \bar{x}_2 \underline{1}, \\ L_{\underline{d}_1} = \sqrt{\sum_{j=1}^n (x_{j1} - \bar{x}_1)^2} & L_{\underline{d}_2} = \sqrt{\sum_{j=1}^n (x_{j2} - \bar{x}_2)^2} \\ = \sqrt{(n-1) S_{11}} & = \sqrt{(n-1) S_{22}} \end{cases}$$

Entonces,



$$A = \text{Area parallelograma} = L_{\underline{d}_2} \times (L_{\underline{d}_1} \sin(\theta))$$

$$\kappa = \angle \underline{d}_2 \angle \underline{d}_1 \sin(\alpha) = \angle \underline{d}_2 \angle \underline{d}_1 \sqrt{1 - \cos^2(\alpha)}$$

$$= \sqrt{(n-1)S_{22}} \sqrt{(n-1)S_{11}} \sqrt{1 - r_{12}^2} \quad (\text{porque } \cos(\alpha) = r_{12})$$

$$= (n-1) \sqrt{S_{22}} \sqrt{S_{11}} \sqrt{1 - r_{12}^2}$$

Teniendo en cuenta que $|S| = (S_{11}S_{22} - S_{12}^2)^2$

$$= S_{11}S_{22} - (\sqrt{S_{11}}\sqrt{S_{22}}r_{12})^2$$

$$= S_{11}S_{22}(1 - r_{12}^2),$$

entonces $|S| = \kappa^2 / (n-1)^2$ y en 'p' dimensiones:

$$\text{Varianza generalizada} = |S| = (n-1)^{-p} (\text{Volumen})^2$$

este es el volumen
generado por los p ejes
de coordenadas.

Considerando la interpretación de una forma cuadrática como una
elipse, y sustituyendo la matriz A en la clase por S^{-1} y
 $\bar{X}$ como el punto fijo, entonces las coordenadas $\underline{X}' = [x_1, x_2, \dots, x_p]$
de los puntos q' están a una distancia este 'c' de $\bar{X}$ satisfacen

$$(\underline{X} - \bar{X})' S^{-1} (\underline{X} - \bar{X}) = c^2.$$

9
La hyper-ellipse definida por $(\underline{X} - \bar{\underline{X}})' S^{-1} (\underline{X} - \bar{\underline{X}}) = c^2$ está
relacionada a la varianza generalizada por la ecuación

$$\text{Volumen de } \{ \underline{X} : (\underline{X} - \bar{\underline{X}})' S^{-1} (\underline{X} - \bar{\underline{X}}) \leq c^2 \} = \frac{2 \pi^{p/2} \cdot c^p \cdot |S|^{1/2}}{p \Gamma(\frac{p}{2})}$$