

ESPERANZA Y MOMENTOS DE UN VECTOR ALEATORIO

(1)

DEFINICION. Sea $(\Omega, \mathcal{A}, P)$ un espacio de probabilidad y $\vec{X}$ una aplicación medible de $(\Omega, \mathcal{A})$ en $(\mathbb{R}^m, \mathcal{B}^m)$, es decir, un vector aleatorio. Si $\vec{g}$ es una aplicación medible y g , definida de $\mathbb{R}^m$ en $\mathbb{R}$, también lo es, la composición $g(\vec{X})$ es una variable aleatoria, cuya esperanza se define de la forma usual. Así, si $g(\vec{X})$ es integrable, entonces

$$E(g(\vec{X})) = \int_{\Omega} g(\vec{X}) dP.$$

Ya sabemos que la anterior expresión tiene un significado en otro tipo de función del tipo de variable aleatoria que $g(\vec{X})$ es. Así, para el caso discreto, sabemos que

$$E(g(\vec{X})) = \sum_{\vec{x} \in A} g(\vec{x}) \cdot P(\vec{X} = \vec{x}) \quad \text{donde } A \text{ es tal que } P(\vec{X} \in A) = 1.$$

Si nos situamos en el caso continuo

$$E(g(\vec{X})) = \int_{\mathbb{R}^m} g(\vec{x}) f(\vec{x}) d\vec{x} = \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} g(x_1, \dots, x_m) f(x_1, \dots, x_m) dx_1 \dots dx_m$$

donde $f(\vec{x})$ es la función de densidad de probabilidad del vector aleatorio $\vec{X}$.

Los conceptos de momentos centrales respecto del origen así como los momentos absolutos y los momentos cruzados tienen una definición paralela a la establecida para el caso de una variable aleatoria estudiada anteriormente con detalle. Surgen así subconjuntos, en esta ocasión, intuitivos meros de interés. En efecto:

a) Si $g(\vec{X}) = X_1^{n_1} \dots X_m^{n_m}$, con $n_i \geq 0$, entonces para $i=1, \dots, m$ a la correspondiente esperanza

$$E(g(\vec{X})) = E(X_1^{n_1} \dots X_m^{n_m})$$

si existe, se conoce como momento conjunto de orden $(n_1, \dots, n_m)$. Se suele denotar mediante $m_{n_1, \dots, n_m}$. Obsérvese que para $n_i = 1, n_j = 0, j \neq i$, tenemos el momento $m_{0, \dots, 1, \dots, 0}$ que coincide con la esperanza de la variable aleatoria X_i (no olvidemos que los componentes del vector aleatorio son todas variables aleatorias).

b) Análogamente, si $g(\vec{X}) = (X_1 - E(X_1))^{n_1} \dots (X_m - E(X_m))^{n_m}$, el momento resultante al obtener la esperanza es conocido como el momento central conjunto de orden $(n_1, \dots, n_m)$.

Los correspondientes momentos absolutos surgirían de manera similar. Por un procedimiento interesante vamos a estudiar el caso bivariente.

VECTOR ALEATORIO BIDIMENSIONAL. Para un vector aleatorio bidimensional (X, Y) , el momento central de orden $(1, 1)$ es conocido con el nombre de covarianza y su definición, cuando existe la correspondiente esperanza es

$$\begin{aligned} \text{cov}(X, Y) &= E((X - E(X))(Y - E(Y))) = E((X - m_{1,0})(Y - m_{0,1})) = E(XY) - E(X)E(Y) \\ &= m_{11} - m_{1,0} \cdot m_{0,1} \end{aligned}$$

Veamos a continuación una interesante propiedad

(2)

DESIGUALDAD DE CAUCHY-SCHWARZ. Sean X e Y dos variables aleatorias con varianzas finitas.

Entonces la $\text{cov}(X, Y)$ existe. Además,

$$[E(XY)]^2 \leq E(X^2) \cdot E(Y^2)$$

Verificándose la igualdad si y solo si existe un número real α tal que $P\{(\alpha X + Y) = 0\} = 1$.
Demostración. Para cualquier par de números reales a, b tenemos

$$|ab| \leq \frac{a^2 + b^2}{2}$$

lo que significa que la $E(XY)$ ni $E(Y^2) < +\infty$ y la $E(X^2) < +\infty$. Procede, para cualquier número real α , a ver

$$E[(\alpha X + Y)^2] = \alpha^2 E(X^2) + 2\alpha E(XY) + E(Y^2)$$

Considerando de una función no negativa, $E[(\alpha X + Y)^2] \geq 0, \forall \alpha$, lo que implica que la ecuación de segundo grado de la derecha de la igualdad tiene como sumo una raíz y por tanto no discriminante más o menos positiva, es decir

$$[E(XY)]^2 \leq E(X^2) \cdot E(Y^2).$$

Obsérvese que si $[E(XY)]^2 = E(X^2) \cdot E(Y^2)$ la ecuación tiene raíz doble, es decir $\alpha_0 = -\frac{E(XY)}{E(X^2)}$, lo que substituido en la ecuación supone que $E[(\alpha_0 X + Y)^2] = 0$ y dado las características de la función $(\alpha_0 X + Y)^2$ las propiedades de la integral de una función no negativa tendremos $P\{(\alpha_0 X + Y) = 0\} = 1$.

Introducido el concepto de covarianza podemos ahora conocer el valor de la variancia de una suma finita de variables aleatorias.

VARIANZA DE UNA SUMA. Sean $X_1, \dots, X_n$ variables aleatorias cuyas varianzas existen. Sean $a_1, \dots, a_n$, números reales. Definimos

$$S = \sum_{i=1}^n a_i X_i.$$

Entonces la variancia de S existe y viene dada por

$$\text{var}(S) = \sum_{i=1}^n a_i^2 \text{var}(X_i) + \sum_{i=1}^n \sum_{j=1, j \neq i}^n a_i a_j \text{cov}(X_i, X_j).$$

En particular si las variables aleatorias son tales que todas las posibles covarianzas son nulas, entonces

$$\text{var}(S) = \sum_{i=1}^n a_i^2 \text{var}(X_i).$$

Demonstración.- El resultado se sigue de desarrollar el cuadrado

$$\left[\sum_{i=1}^n a_i x_i - \sum_{i=1}^n a_i E(x_i) \right]^2$$

y después tomar esperanzas.

ALGUNAS DESIGUALDADES DE INTERÉS

Lema.- Para a, b reales cualesquiera, tenemos

$$|a+b|^r \leq C_r (|a|^r + |b|^r), \text{ donde } C_r = 1, \text{ si } 0 \leq r \leq 1 \text{ y } C_r = 2^{r-1} \text{ si } r > 1.$$

Demonstración.- Para $r=0$ y $r=1$ la desigualdad es trivialmente cierta. Obtengamos por otra parte que bastará comprobar la desigualdad para $0 < a \leq b$. Así pues, $0 < a \leq b$, hagamos $x = a/b$. Entonces

$$\frac{(a+b)^r}{a^r + b^r} = \frac{(1+x)^r}{1+x^r}$$

Sea $f(x) = (1+x)^r / (1+x^r)$, en definitiva vale

$$f'(x) = \frac{r(1+x)^{r-1}}{(1+x^r)^2} (1-x^{r-1}), \quad 0 < x \leq 1, \quad r > 0.$$

Se sigue que $f'(x) > 0$, si $r > 1$, para $r=1$, entonces $f'(x) = 0$ y para $r < 1$, entonces $f'(x) \leq 0$. En consecuencia

$$\max_{0 \leq x \leq 1} f(x) = f(0) = 1, \quad \text{si } r \leq 1$$

$$\max_{0 \leq x \leq 1} f(x) = f(1) = 2^{r-1}, \quad \text{si } r \geq 1.$$

Con lo que queda demostrado el lema.

Obsérvese que hubiéramos podido obtener, de inmediato, una cota del tipo

$$|a+b|^r \leq 2^r (|a|^r + |b|^r)$$

puesto que

$$|a+b| \leq \max(2|a|, 2|b|)$$

y de aquí al elevar a la r -ésima potencia obtenemos la desigualdad anterior.

Como una aplicación de esta desigualdad obtenida en el lema tenemos la siguiente propiedad.

TEOREMA.- Sean X y Y variables aleatorias y $r > 0$ un número fijo. Si $E(|X|^r)$ y $E(|Y|^r)$ son ambos finitos, entonces también lo es $E(|X+Y|^r)$.

Demonstración.- Basta tomar $a=X$, $b=Y$ y aplicar la desigualdad anterior, luego tomamos esperanzas y llegamos al resultado enunciado en el teorema.

③ DESIGUALDAD DE HÖLDER.- Para x y y reales cualesquiera y para p, q , dos números reales positivos tales que $p > 1$ y $1/p + 1/q = 1$, tenemos

$$|xy| \leq \frac{|x|^p}{p} + \frac{|y|^q}{q}$$

Demonstración.- Obsérvese que para $x > 0$, la función $w = \log x$ es concava, por tanto para $0 < t < 1$ y para $x_1 > 0, x_2 > 0$, tenemos

$$\log [tx_1 + (1-t)x_2] \geq t \log x_1 + (1-t) \log x_2.$$

Tomando antilogaritmos, tenemos

$$x_1^t \cdot x_2^{(1-t)} \leq tx_1 + (1-t)x_2.$$

Elegimos ahora $x_1 = |x|^p$, $x_2 = |y|^q$, $t = 1/p$, $1-t = 1/q$, con $p > 1$ y $1/p + 1/q = 1$, llegando entonces a

$$|xy| \leq \frac{|x|^p}{p} + \frac{|y|^q}{q}$$

desigualdad conocida como la desigualdad de Hölder.

Aplicando la desigualdad de Hölder obtenemos otra conocida desigualdad en términos de

DESIGUALDAD DE MINKOWSKI.- Para $p \geq 1$

$$\{E[|X+Y|^p]\}^{1/p} \leq \{E(|X|^p)\}^{1/p} + \{E(|Y|^p)\}^{1/p}$$

Demonstración.- El caso $p=1$ es simplemente inmediato del hecho $|X+Y| \leq |X| + |Y|$. Sea $p > 1$, tenemos

$$|X+Y|^p = |X+Y| \cdot |X+Y|^{p-1} \leq |X| \cdot |X+Y|^{p-1} + |Y| \cdot |X+Y|^{p-1}$$

tomando esperanzas y utilizando la desigualdad de

esperanzas que, a su vez, obteniendo también como la desigualdad de Hölder.

DESIGUALDAD DE HÖLDER PARA ESPERANZAS.- Sean $p > 1, q > 1$ tales que $1/p + 1/q = 1$.

Entonces

$$E(|XY|) \leq \{E(|X|^p)\}^{1/p} \{E(|Y|^q)\}^{1/q}.$$

Demonstración.- Utilizando la desigualdad de Hölder, con $x = X \{E(|X|^p)\}^{-1/p}$ e $y = Y \{E(|Y|^q)\}^{-1/q}$ llegamos a

$$|XY| \leq p^{-1} |X|^p \{E(|X|^p)\}^{1/p-1} \{E(|Y|^q)\}^{1/q} + q^{-1} |Y|^q \{E(|Y|^q)\}^{1/q-1} \{E(|X|^p)\}^{1/p}$$

tomando esperanzas llegamos a la desigualdad buscada.

Un corolario importante de esta última desigualdad nos conduce a la ya conocida desigualdad de Cauchy-Schwarz. En efecto, para $p=q=2$, tenemos

$$E(|XY|) \leq \{E(X^2)\}^{1/2} \cdot \{E(Y^2)\}^{1/2},$$

que puede también escribirse bajo la forma más conocida

$$\{E(XY)\}^2 \leq E(X^2) \cdot E(Y^2).$$

Finalicemos con una desigualdad debida a Minkowski.

DESIGUALDAD DE MINKOWSKI. - Para $p \geq 1$,

$$\{E(|X+Y|^p)\}^{1/p} \leq \{E(|X|^p)\}^{1/p} + \{E(|Y|^p)\}^{1/p}.$$

Demostración. - Para $p=1$, la desigualdad es consecuencia inmediata de $|X+Y| \leq |X| + |Y|$.

Sea $p > 1$, entonces

$$|X+Y|^p = |X+Y| \cdot |X+Y|^{p-1} \leq |X| \cdot |X+Y|^{p-1} + |Y| \cdot |X+Y|^{p-1}$$

tomando esperanzas y utilizando la desigualdad de Hölder, en la que tenemos $q = |X+Y|^{p-1}$ ($p > 1$), tenemos

$$\begin{aligned} E(|X+Y|^p) &\leq \{E(|X|^p)\}^{1/p} \cdot \{E(|X+Y|^{(p-1)q})\}^{1/q} + \{E(|Y|^p)\}^{1/p} \cdot \{E(|X+Y|^{(p-1)q})\}^{1/q} \\ &= [\{E(|X|^p)\}^{1/p} + \{E(|Y|^p)\}^{1/p}] \cdot \{E(|X+Y|^{(p-1)q})\}^{1/q}. \end{aligned}$$

Excluyendo el caso trivial en que $E(|X+Y|^p) = 0$, y teniendo en cuenta que $(p-1)q = p$, reagrupando adecuadamente en la anterior desigualdad llegamos al resultado buscado.

ESPERANZA CONDICIONADA

Recordemos que si $\vec{X}$ es un vector aleatorio al que haccionamos en dos subvectores $\vec{X}_1, \vec{X}_2$, para $\vec{X}_1 = \vec{x}_1$ tal que $f_{\vec{X}_1}(\vec{x}_1) > 0$, la función

$$f_{\vec{X}_2/\vec{X}_1}(\vec{x}_2) = \frac{f(\vec{x})}{f_{\vec{X}_1}(\vec{x}_1)}, \text{ con } \vec{x} = (\vec{x}_1, \vec{x}_2) \text{ y } f \text{ la f.d.p. conjunta}$$

define una f.d.p.; más concretamente define una distribución de probabilidad para el subvector $\vec{X}_2$ condicionada a que el otro subvector $\vec{X}_1$ tome un valor fijo $\vec{x}_1$.

Podríamos pues intentar estudiar la esperanza de este subvector condicionado, utilizando para ello la correspondiente f.d.p. y la definición usual ya establecida para el concepto de esperanza. Por motivos de simplicidad vamos a centrarnos ahora en el caso de un vector bidimensional en el que los subvectores sean cada una de las variables que lo componen, la generalización a dimensiones mayores es inmediata.

DEFINICIÓN. - Sea $\vec{X} = (X, Y)$ un vector aleatorio definido sobre el espacio de probabilidad $(\Omega, \mathcal{A}, P)$ y sea h una función medible definida de $\mathbb{R}$ en $\mathbb{R}$. Supongamos que existe la $E(h(\vec{X}))$. Entonces la esperanza condicionada de $h(X)$, dado Y , que se escribe $E(h(X)/Y)$, es una variable aleatoria que toma el valor $E(h(X)/y)$, definido adelante

$$E(h(X)/y) = \int_{\Omega} h(x) \cdot dP_{Y=y}$$

donde $P_{Y=y}$ quiere significar la distribución de probabilidad condicionada al hecho de que Y tome el valor y . Según el tipo de vector aleatorio que sea $\vec{X} = (X, Y)$ aquella expresión adopta la forma:

$$1) \quad E(h(X)/y) = \left[h(x) \cdot P(X=x/Y=y) \right]_{x \in A} = \left[h(x) \cdot \frac{f(x,y)}{f_2(y)} \right]_{x \in A}$$

donde $A = B_y$, la unión de B mediante y , siendo B tal que $P(\vec{X} \in B) = 1$.

Esto para el caso en que $\vec{X}$ sea un vector aleatorio del tipo discreto.

2) En el caso continuo

$$E(h(X)/y) = \int_{\mathbb{R}} h(x) \cdot f_{X/Y}(x) dx = \int_{\mathbb{R}} h(x) \cdot \frac{f(x,y)}{f_2(y)} dx$$

Obsérvese que en ambos casos $E(h(X)/y)$ es, efectivamente, una función del valor y .

Obrinamente, una definición análoga puede darse para $E(h_1(X)/Y)$, siempre que exista $E(h_1(X))$. (7)

Dada la definición establecida es evidente que la esperanza Condicionada goza de todas las propiedades inherentes al concepto de esperanza y que ya hemos estudiado. Recordemos a título de ejemplo:

PROPIEDADES DE LA ESPERANZA CONDICIONADA

- $E(c/Y) = c$, donde c es constante.
- $E(aX + b/Y) = aE(X/Y) + b$, a, b constantes.
- Si h_1 y h_2 son funciones medibles, de manera que sus esperanzas, $E(h_i(X))$ existen, tenemos

$$E\{[a_1 h_1(X) + a_2 h_2(X)]/Y\} = a_1 E(h_1(X)/Y) + a_2 E(h_2(X)/Y).$$
- Si $X \geq 0$, entonces $E(X/Y) \geq 0$.
- Si $X_1 \geq X_2$, entonces $E(X_1/Y) \geq E(X_2/Y)$.

Momentos de todo tipo de una distribución de probabilidad condicional se definen de forma análoga a como se establecieron en un principio y gozan también, claro está, de las mismas propiedades. Sin embargo, las características especiales de este tipo de distribuciones son lugar a algunas propiedades que las caracterizan. Veámoslas.

PROPIEDAD 1. - Si $E(h(X))$ existe, entonces

$$E[E(h(X)/Y)] = E(h(X)).$$

Demostración. - Si X es un vector aleatorio continuo, entonces la v.a. $E(h(X)/Y)$ viene definida mediante

$$g(y) = E(h(X)/Y) = \int_{\mathbb{R}} h(x) \frac{f(x,y)}{f_2(y)} dx$$

como función medible de la variable aleatoria Y que es, por esperanza vendida dada por

$$\begin{aligned} E[g(Y)] &= \int_{\mathbb{R}} g(y) \cdot f_2(y) dy = \int_{\mathbb{R}} \left[\int_{\mathbb{R}} h(x) \cdot \frac{f(x,y)}{f_2(y)} dx \right] f_2(y) dy = \\ &= \int_{\mathbb{R}} \left[\int_{\mathbb{R}} h(x) \cdot f(x,y) dx \right] dy = \int_{\mathbb{R}} h(x) \left[\int_{\mathbb{R}} f(x,y) dy \right] dx = \\ &= \int_{\mathbb{R}} h(x) f_1(x) dx = E(h(X)). \end{aligned}$$

Para el caso discreto la demostración es análoga. (8)

PROPIEDAD 2. - Si $E(X^2) < +\infty$, entonces

$$\text{var}(X) = \text{var}(E(X/Y)) + E(\text{var}(X/Y)).$$

Demostración. - Haciendo uso de la propiedad anterior, sabemos que

$$\begin{aligned} \text{var}(X) &= E((X - E(X))^2) = E[E((X - E(X))^2/Y)] = E[E\{(X^2 + (E(X))^2 - 2XE(X))/Y\}] = \\ &= E[E(X^2/Y) + (E(X))^2 - 2E(X)E(X/Y)] = E[E(X^2/Y) - E(X/Y)^2 + (E(X))^2 + \\ &\quad + (E(X))^2 - 2E(X)E(X/Y)] = E[\text{var}(X/Y) + (E(X/Y) - E(X))^2] = \\ &= E(\text{var}(X/Y)) + E[(E(X/Y) - E(X))^2] = E(\text{var}(X/Y)) + \text{var}(E(X/Y)). \end{aligned}$$

COROLARIO. - Si $E(X^2) < +\infty$, entonces de la propiedad 2 se sigue de inmediato que

$$\text{var}(X) \geq \text{var}(E(X/Y)).$$

Obsérvese por otra parte que cuando se verifica la igualdad $\text{var}(X) = \text{var}(E(X/Y))$, ello supone que

$$E(\text{var}(X/Y)) = 0$$

o sea

$$E((X - E(X/Y))^2/Y) = 0$$

y de acuerdo con las propiedades de los integrales de funciones medibles no negativas, ello supone que la función $(X - E(X/Y))^2$

es nula casi por todas partes, o sea

$$P(X = E(X/Y)) = 1$$

lo que supone que X es, casi por todas partes, una función de Y , por cuanto $E(X/Y)$ lo es.

EL PRINCIPIO DE LOS MINIMOS CUADRADOS

(9)

Sean X e Y dos variables aleatorias de manera que existe entre ellas una relación de dependencia que deseamos determinar. Supongamos que $E(Y^2)$ y $E[h(X)^2]$ son finitas, buscaremos a partir de encontrar una función $h(x)$ que aproxime el valor de la relación funcional entre X e Y .

El principio de los mínimos cuadrados consiste en la elección de $h(x)$ de tal suerte que la cantidad

$$E\{(Y - h(X))^2\}$$

sea mínima. ¿Cuál ha de ser entonces $h(x)$?

Observemos que, si (X, Y) es un vector aleatorio continuo, tenemos

$$\begin{aligned} E\{(Y - h(X))^2\} &= \int_{\mathbb{R}^2} [Y - h(X)]^2 f_{X,Y}(x,y) dx dy = \int_{\mathbb{R}^2} [Y - h(X)]^2 f_{Y/X}(y) f_X(x) dy dx = \\ &= \int_{\mathbb{R}} f_X(x) \left\{ \int_{\mathbb{R}} [Y - h(X)]^2 f_{Y/X}(y) dy \right\} dx, \end{aligned}$$

que sea mínima esta expresión supone que se minimiza lo que figura entre llaves en el integrando y de acuerdo con las propiedades estudiadas para la varianza, dicha cantidad se minimiza tal cuando $h(x) = E(Y/X)$.

Un resultado análogo se verifica por el caso en que (X, Y) es discreto.

DEFINICIÓN - la relación $y = E(Y/X)$ se conoce como la regresión de Y sobre X , análogamente $x = E(X/Y)$ es la regresión de X sobre Y .

LÍNEA DE REGRESIÓN - En ocasiones, por motivos de sencillez fundamentalmente, resulta interesante en aproximar la relación entre X e Y mediante una línea recta, $y = ax + b$. En esta situación y haciendo uso del principio de los mínimos cuadrados antes citado, a y b deberán ser elegidos de manera que

$$L = E\{(Y - ax - b)^2\}$$

sea mínimo. Siempre bajo el supuesto de la existencia de $E(Y^2)$ y $E(X^2)$, la elección de a y b se reduce a un problema de máximos y mínimos, buscando en derivar parcialmente L respecto a ambos parámetros e igualar, posteriormente, a cero dichas derivadas. Se obtienen así para a y b, las expresiones

$$a = \frac{\text{Cov}(X, Y)}{\text{Var}(X)}, \quad b = E(Y) - E(X) \frac{\text{Cov}(X, Y)}{\text{Var}(X)}$$

haciendo la ecuación de la recta, conocida como línea de regresión de Y sobre X ,

$$Y - E(Y) = \frac{\text{Cov}(X, Y)}{\text{Var}(X)} (X - E(X)). \quad (1)$$

Una expresión análoga se obtiene para la línea de regresión de X sobre Y , a saber (10)

$$X - E(X) = \frac{\text{Cov}(X, Y)}{\text{Var}(Y)} (Y - E(Y)). \quad (2)$$

Obsérvese que la relación (2) no se obtiene a partir de la (1) despejando en aquella $X - E(X)$, puesto que en ambas relaciones los papeles de X e Y aparecen cambiados. La relación (1) se obtiene considerando a X como variable casual, mientras que en la (2) este papel viene desempeñado por Y .

Un procedimiento análogo permitiría aproximar la relación entre X e Y mediante un polinomio de grado n , por ejemplo, $y = a + bx + cx^2 + dx^3$, para $n=3$.

DEFINICIÓN - Si $E(X^2)$ y $E(Y^2)$ existen, a las cantidades

$$r_{Y/X} = \frac{\text{Cov}(X, Y)}{\text{Var}(Y)} \quad \text{y} \quad r_{X/Y} = \frac{\text{Cov}(X, Y)}{\text{Var}(X)}$$

se les designa coeficientes de regresión lineal de Y sobre X y X sobre Y respectivamente, pero al revés.

DEFINICIÓN - Si $E(X^2)$ y $E(Y^2)$ existen, se define el coeficiente de correlación lineal entre X e Y , mediante

$$\rho = \frac{\text{Cov}(X, Y)}{(\text{Var}(X) \text{Var}(Y))^{1/2}}$$

a

$$\rho^2 = r_{Y/X} \cdot r_{X/Y}$$

se le denomina coeficiente de determinación. Obsérvese que el signo de ρ es el mismo que el de la $\text{Cov}(X, Y)$.

DEFINICIÓN - Decimos que dos variables X e Y son independientes si y sólo si $\rho = 0$.

Obviamente si $\text{Cov}(X, Y) = 0$, entonces $\rho = 0$ y las variables son independientes. Posteriormente, cuando introduzcamos el concepto de independencia entre variables, volveremos sobre este concepto.

A continuación estudiaremos algunas propiedades básicas del coeficiente de correlación.

PROPIEDAD 1 - a) El coeficiente de correlación lineal entre X e Y satisface la relación

$$|\rho| \leq 1.$$

b) la igualdad $\rho = \pm 1$ se verifica si existen constantes a y b tales que

$$P\{Y = aX + b\} = 1.$$

Demonstración - a) Recordemos que de acuerdo con la desigualdad de Cauchy-Schwarz

$$[\text{Cov}(X, Y)]^2 \leq \text{Var}(X) \text{Var}(Y).$$

y de aquí la desigualdad del enunciado.

b) Además, recordemos que si $\rho = \pm 1$, entonces $[\text{Cov}(X, Y)]^2 = \text{Var}(X) \text{Var}(Y)$

EL PRINCIPIO DE LOS MINIMOS CUADRADOS

(9)

Sean X e Y dos variables aleatorias de manera que existe entre ellas una relación de dependencia que deseamos determinar. Supongamos que $E(Y^2)$ y $E[h(X)^2]$ son finitas, buscaremos a partir de encontrar una función $h(x)$ que aproxime el valor de la relación funcional entre X e Y .

El principio de los mínimos cuadrados consiste en la elección de $h(x)$ de tal suerte que la cantidad

$$E\{(Y - h(X))^2\}$$

sea mínima. ¿Cuál ha de ser entonces $h(x)$?

Observemos que, si (X, Y) es un vector aleatorio continuo, tenemos

$$\begin{aligned} E\{(Y - h(X))^2\} &= \int_{\mathbb{R}^2} [Y - h(X)]^2 f(x, y) dx dy = \int_{\mathbb{R}^2} [Y - h(X)]^2 f_{Y/X}(y) f_X(x) dy dx = \\ &= \int_{\mathbb{R}} f_X(x) \left\{ \int_{\mathbb{R}} [Y - h(X)]^2 f_{Y/X}(y) dy \right\} dx, \end{aligned}$$

que sea mínima esta expresión supone que se minimiza lo que figura entre llaves en el integrando y de acuerdo con las propiedades estudiadas para la variancia, dicha cantidad se minimiza tal cuando $h(x) = E(Y/X)$.

Un resultado análogo se verifica por el caso en que (X, Y) es discreto.

DEFINICION - la relación $y = E(Y/X)$ se conoce como la regresión de Y sobre X , análogamente $x = E(X/Y)$ es la regresión de X sobre Y .

LINEA DE REGRESION - En ocasiones, por motivos de sencillez fundamentalmente, resulta interesante en aproximar la relación entre X e Y mediante una línea recta, $y = ax + b$. En esta situación y haciendo uso del principio de los mínimos cuadrados antes citado, a y b deberán ser elegidos de manera que

$$L = E\{(Y - ax - b)^2\}$$

sea mínimo. Siempre bajo el supuesto de la existencia de $E(Y^2)$ y $E(X^2)$, la elección de a y b se reduce a un problema de máximos y mínimos, bastando con derivar parcialmente L respecto a ambos parámetros e igualar, posteriormente, a cero dichas derivadas. Se obtienen así para a y b, las expresiones

$$a = \frac{\text{Cov}(X, Y)}{\text{Var}(X)}, \quad b = E(Y) - E(X) \frac{\text{Cov}(X, Y)}{\text{Var}(X)}$$

haciendo la ecuación de la recta, conocida como línea de regresión de Y sobre X ,

$$Y - E(Y) = \frac{\text{Cov}(X, Y)}{\text{Var}(X)} (X - E(X)). \quad (1)$$

Una expresión análoga se obtiene para la línea de regresión de X sobre Y , a saber (10)

$$X - E(X) = \frac{\text{Cov}(X, Y)}{\text{Var}(Y)} (Y - E(Y)). \quad (2)$$

Obsérvese que la relación (2) no se obtiene a partir de la (1) despejando en aquella $X - E(X)$, puesto que en ambas relaciones los papeles de X e Y aparecen cambiados. La relación (1) se obtiene considerando a X como variable casual, mientras que en la (2) este papel viene desempeñado por Y .

Un procedimiento análogo permitiría aproximar la relación entre X e Y mediante un polinomio de grado n , por ejemplo, $y = a + bx + cx^2 + dx^3$, para $n=3$.

DEFINICION - Si $E(X^2)$ y $E(Y^2)$ existen, a las cantidades

$$r_{Y/X} = \frac{\text{Cov}(X, Y)}{\text{Var}(Y)} \quad \text{y} \quad r_{X/Y} = \frac{\text{Cov}(X, Y)}{\text{Var}(X)}$$

se les designa coeficientes de regresión lineal de Y sobre X y X sobre Y respectivamente, pero al revés.

DEFINICION - Si $E(X^2)$ y $E(Y^2)$ existen, se define el coeficiente de correlación lineal entre X e Y , mediante

$$\rho = \frac{\text{Cov}(X, Y)}{(\text{Var}(X) \text{Var}(Y))^{1/2}}$$

a

$$\rho^2 = r_{Y/X} \cdot r_{X/Y}$$

se le denomina coeficiente de determinación. Obsérvese que el signo de ρ es el mismo que el de la $\text{Cov}(X, Y)$.

DEFINICION - Decimos que dos variables X e Y son independientes si y sólo si $\rho = 0$.

Obviamente si $\text{Cov}(X, Y) = 0$, entonces $\rho = 0$ y las variables son independientes. Posteriormente, cuando introduzcamos el concepto de independencia entre variables, volveremos sobre este concepto.

A continuación estudiaremos algunas propiedades básicas del coeficiente de correlación.

PROPIEDAD 1 - a) El coeficiente de correlación lineal entre X e Y satisface la relación

$$|\rho| \leq 1.$$

b) la igualdad $\rho = \pm 1$ se verifica si existen constantes a y b tales que

$$P\{Y = aX + b\} = 1.$$

Demonstración - a) Recordemos que de acuerdo con la desigualdad de Cauchy-Schwarz

$$[\text{Cov}(X, Y)]^2 \leq \text{Var}(X) \text{Var}(Y).$$

y de aquí la desigualdad del enunciado.

b) Además, recordemos que si $\rho = \pm 1$, entonces $[\text{Cov}(X, Y)]^2 = \text{Var}(X) \text{Var}(Y)$

y ello ocurre si y solo si $P\{aX+Y=0\}=1$, que es de la forma $P\{Y=aX+b\}=1$, mediante una adecuada elección de Y .

(11)

COROLARIO.- Las dos líneas de regresión (1) y (2) coinciden si y solo si $\rho=1$ o $\rho=-1$.

PROPIEDAD 2.- Sean $E(X^2)<+\infty$, $E(Y^2)<+\infty$ y hagamos $U=aX+b$, $V=cY+d$, entonces

$$\rho_{X,Y} = \pm \rho_{U,V},$$

donde $\rho_{X,Y}$ y $\rho_{U,V}$ son, respectivamente, los coeficientes de correlación lineal de X e Y y de U y V .

Demstración.- La propiedad se deriva de las propiedades de los momentos ya estudiadas.

EJEMPLOS

① Sea (X,Y) un vector aleatorio con función de densidad conjunta

$$f(x,y) = \begin{cases} x+y & , 0 < x < 1, 0 < y < 1 \\ 0 & , \text{en el resto.} \end{cases}$$

Entonces

$$\begin{aligned} E(X^l Y^m) &= \int_0^1 \int_0^1 x^l y^m (x+y) dx dy = \int_0^1 \int_0^1 x^{l+1} y^m dx dy + \int_0^1 \int_0^1 x^l y^{m+1} dx dy \\ &= \frac{1}{(l+2)(m+1)} + \frac{1}{(l+1)(m+2)}, \text{ en } l, m \text{ enteros positivos.} \end{aligned}$$

A partir de este resultado, tenemos

$$l=1, m=0, \quad E(X) = \frac{7}{12}, \quad l=0, m=1, \quad E(Y) = \frac{7}{12}.$$

$$l=2, m=0, \quad E(X^2) = \frac{5}{12}, \quad l=0, m=2, \quad E(Y^2) = \frac{5}{12}$$

$$\text{var}(X) = \frac{5}{12} - \frac{49}{144} = \frac{11}{144} = \text{var}(Y)$$

$$\text{Cov}(X,Y) = E(XY) - E(X)E(Y) = \frac{1}{3} - \frac{49}{144} = \frac{48-49}{144} = -\frac{1}{144}.$$

② Recordemos el ejemplo 5 (pág. 8, de Vectores aleatorios). El vector aleatorio (X,Y) , con f.d.p. conjunta

$$f(x,y) = \begin{cases} 2 & , 0 < x < y < 1 \\ 0 & , \text{en el resto} \end{cases}$$

tenía por densidades marginales $f_1(x) = 2(1-x)$, $0 < x < 1$
0, en el resto

$$y \quad f_2(y) = 2y, \quad 0 < y < 1 \\ 0, \quad \text{en el resto.}$$

(12)

Analicemos las funciones de densidad condicionadas, vienen dadas por (véase ejemplo 7, pág. 13 del mismo capítulo)

$$f_{Y/X}(x) = \frac{1}{y}, \quad 0 < x < y$$

$$f_{X/Y}(y) = \frac{1}{1-x}, \quad x < y < 1.$$

En ambos casos se trata de distribuciones de probabilidad uniformes en el correspondiente intervalo. A partir de aquí

$$E(Y/X) = \int_x^1 y f_{Y/X}(y) dy = \int_x^1 y \cdot \frac{1}{1-x} dy = \frac{1}{1-x} \cdot \frac{1-x^2}{2} = \frac{1+x}{2}, \quad 0 < x < 1.$$

$$E(X/Y) = \int_0^y x f_{X/Y}(x) dx = \int_0^y x \cdot \frac{1}{y} dx = \frac{1}{y} \cdot \frac{y^2}{2} = \frac{y}{2}, \quad 0 < y < 1.$$

Análogamente

$$E(X^2/Y) = \int_0^y x^2 \cdot \frac{1}{y} dx = \frac{1}{y} \cdot \frac{y^3}{3} = \frac{y^2}{3}, \quad 0 < y < 1$$

y por tanto

$$\text{var}(X/Y) = E(X^2/Y) - [E(X/Y)]^2 = \frac{y^2}{3} - \frac{y^2}{4} = \frac{y^2}{12}, \quad 0 < y < 1$$

Por otro parte

$$\begin{aligned} E(X) &= \int_0^1 x f_1(x) dx = \int_0^1 x \cdot 2(1-x) dx = \int_0^1 (2x - 2x^2) dx = \left[x^2 - \frac{2x^3}{3} \right]_0^1 = \\ &= 1 - \frac{2}{3} = \frac{1}{3} \end{aligned}$$


pero

$$E(E(X/Y)) = \int_0^1 E(X/Y) f_2(y) dy = \int_0^1 \frac{y}{2} \cdot 2y dy = \int_0^1 y^2 dy = \left[\frac{y^3}{3} \right]_0^1 = \frac{1}{3},$$

que coincide, como ya sabemos, con $E(X)$.

③ La igualdad $E(X) = E(E(X/Y))$ es en ocasiones muy útil para obtener la primera de las esperanzas a partir de la segunda, cuando la obtención directa de esta es complicada. Veamos el siguiente ejemplo:

"Un trabajador opera con determinado tipo de máquinas en un número n . Las máquinas están alineadas y separadas entre sí una distancia a . Supongamos que el operador se traslada de una máquina a otra según un orden de prioridad totalmente aleatorio. Encontrar la longitud media del camino que recorre el operador para atender dos máquinas consecutivamente".



Numéramos las máquinas de izquierda a derecha, de 1 a n , y denotemos por B_k el suceso "el operador está atendiendo la máquina k ". Puesto que las máquinas son todas del mismo tipo, el orden de prioridad es aleatorio, la probabilidad P_i^k , de que la próxima máquina en requerir los servicios del operador sea la i , es $1/n$ ($1 \leq i \leq n$). La longitud del camino que deberá recorrer el operador para atender dicha máquina, medido en a unidades, es

$$\lambda_i^k = \begin{cases} (k-i)a, & k \geq i \\ (i-k)a, & k < i \end{cases}$$

denotando por λ la v.a. correspondiente, tenemos

$$\begin{aligned} E(\lambda/B_k) &= \sum_{i=1}^n \lambda_i^k \cdot P_i^k = \frac{1}{n} \left[\sum_{i=1}^k (k-i)a + \sum_{i=k+1}^n (i-k)a \right] = \\ &= \frac{a}{n} \left[\frac{k(k-1)}{2} + \frac{(n-k)(n-k+1)}{2} \right] = \frac{a}{2n} [2k^2 - 2k(n+1) + n(n+1)] \end{aligned}$$

Por otra parte la probabilidad de que el operador esté atendiendo a la máquina k , es la misma para todos los k , es decir $P(B_k) = \frac{1}{n}$, $1 \leq k \leq n$, de acuerdo con esto

$$\begin{aligned} E(\lambda) &= E[E(\lambda/B_k)] = \sum_{k=1}^n E(\lambda/B_k) \cdot P(B_k) = \\ &= \sum_{k=1}^n \frac{a}{2n^2} [2k^2 - 2k(n+1) + n(n+1)] = \frac{a}{2n^2} \left[2 \sum_{k=1}^n k^2 - 2(n+1) \sum_{k=1}^n k + n^2(n+1) \right] \\ &= \frac{a}{2n^2} \left[2 \cdot \frac{n(n+1)(2n+1)}{6} - 2(n+1) \cdot \frac{n(n+1)}{2} + n^2(n+1) \right] = \end{aligned}$$

$$\begin{aligned} &= \frac{a}{2n^2} \left[\frac{n(n+1)(2n+1)}{3} - n(n+1) \right] = \frac{a}{2n^2} \left[n(n+1) \left\{ \frac{2n+1}{3} - 1 \right\} \right] = \\ &= \frac{a}{2n^2} \cdot \frac{n(n+1)}{3} \cdot (2n-2) = \frac{2an}{6n^2} (n^2-1) = \frac{a(n^2-1)}{3n} = \frac{a(n+1)}{3n} = \boxed{\frac{a}{3} \left(1 + \frac{1}{n} \right)} \end{aligned}$$

④ Sea (X, Y) un vector aleatorio con densidad conjunta dada por

$$f(x, y) = \begin{cases} e^{-y}, & 0 < x < y < +\infty \\ 0, & \text{en el resto.} \end{cases}$$

las correspondientes marginales tendrán dadas por

$$\begin{aligned} f_1(x) &= \int_{\mathbb{R}} f(x, y) dy = \int_x^{+\infty} e^{-y} dy = (-e^{-y})_x^{+\infty} = e^{-x}, & 0 < x < +\infty \\ &= 0, & \text{en el resto.} \end{aligned}$$

$$\begin{aligned} f_2(y) &= \int_{\mathbb{R}} f(x, y) dx = \int_0^y e^{-y} dx = e^{-y} y, & 0 < y < +\infty \\ &= 0, & \text{en el resto.} \end{aligned}$$

A partir de aquí las densidades condicionales se obtienen fácilmente,

$$\begin{aligned} f_{X/Y}(x) &= \frac{f(x, y)}{f_2(y)} = \frac{e^{-y}}{e^{-y} y} = \frac{1}{y}, & 0 < x < y \\ &= 0, & \text{en el resto.} \end{aligned}$$

$$\begin{aligned} f_{Y/X}(y) &= \frac{f(x, y)}{f_1(x)} = \frac{e^{-y}}{e^{-x}} = e^{x-y}, & x < y < +\infty \\ &= 0, & \text{en el resto.} \end{aligned}$$

Entonces

$$E(X/Y) = \int_{\mathbb{R}} x f_{X/Y}(x) dx = \int_0^y x \cdot \frac{1}{y} dx = \frac{1}{y} \cdot \frac{y^2}{2} = \frac{y}{2}, \quad 0 < y < +\infty$$

$$E(Y/X) = \int_{\mathbb{R}} y f_{Y/X}(y) dy = \int_x^{+\infty} y \cdot e^{x-y} dy = \int_0^{+\infty} (u+x) e^{-u} du = x+1, \quad 0 < x < +\infty$$

En este caso la relación entre $E(X/Y)$ y $E(Y/X)$ es la misma que en otros casos, coincidiendo con las líneas de regresión de X sobre Y y Y sobre X . De acuerdo con esto los coeficientes de regresión

valdrán

$$\gamma_{x/x} = \frac{1}{2}, \quad \gamma_{y/x} = 1.$$

Por tanto

$$\sigma^2 = \gamma_{x/x} \cdot \gamma_{y/x} = \frac{1}{2}$$

y

$$\sigma = +\sqrt{\frac{1}{2}}$$

stando el signo determinado a partir del signo de la covarianza. La covarianza viene dada por

$$\text{cov}(x, y) = E(xy) - E(x) \cdot E(y)$$

Se comprueba que

$$E(xy) = \int_0^{+\infty} \int_0^y xy e^{-y} dx dy = 3$$

$$E(x) = \int_0^{+\infty} x e^{-x} dx = 1, \quad E(y) = \int_0^{+\infty} y^2 e^{-y} dy = 2$$

y por tanto

$$\text{cov}(x, y) = 3 - 2 = 1.$$

MATRIZ DE COVARIANZAS DE UN VECTOR ALEATORIO

Ya hemos dicho que para un vector aleatorio, $\vec{X}$, de dimensión n , la esperanza $E((x_1 - E(x_1))^{p_1} (x_2 - E(x_2))^{p_2} \dots (x_n - E(x_n))^{p_n})$ se conoce como el momento central conjunto de orden $(p_1, p_2, \dots, p_n)$. En función del orden del momento mide asociado a la suma de los exponentes, en este caso diremos que el momento es de orden $p_1 + p_2 + \dots + p_n$. De cuando en esta nomenclatura tienen especial interés todos los momentos de segundo orden, centrales, de un vector aleatorio. En efecto, los momentos de segundo orden de $\vec{X}$, supone que de los $p_i, i=1, \dots, n$, a lo sumo 2 son distintos de cero, y los dos últimos (en número) así pos, puede ocurrir que $p_i=1, p_j=1, p_k=0, k \neq i, k \neq j$, o bien, $p_i=2, p_j=0, j \neq i$. De la primera de estas situaciones lo que entendemos será la covarianza entre las variables x_i y x_j , en la segunda entendemos la varianza de i . Designemos por σ_{ij} la covarianza citada y por σ_{ii} la varianza. Es costumbre disponer estos valores en una matriz cuadrada de dimensión n , a la que se suele denotar mediante Σ , y que puede ser conocida

$$\Sigma = \begin{bmatrix} \sigma_{11} & \dots & \sigma_{1n} \\ \sigma_{21} & & \sigma_{2n} \\ \vdots & \sigma_{ij} & \vdots \\ \sigma_{n1} & \dots & \sigma_{nn} \end{bmatrix}$$

como la matriz de covarianzas del vector aleatorio $\vec{X}$. Obsérvese que los elementos de Σ son las covarianzas entre las variables x_i y x_j (fila y columna respectivamente del elemento σ_{ij}). Los elementos de la diagonal principal σ_{ii} son las varianzas de la correspondiente variable, a saber, x_i . Además, dada la definición de covarianza, la matriz es, evidentemente, simétrica, de forma que $\sigma_{ij} = \sigma_{ji}$. La matriz de covarianzas es un parámetro muy importante en el conocimiento de las características de la distribución de probabilidad de un vector aleatorio, supone, en cierta manera, la generalización del concepto de varianza para el caso multidimensional.

Por ejemplo, en el anterior ejemplo nº 1 de la página, tenemos un vector bidimensional, cuya matriz de covarianzas, de 2×2 , en este caso viene dada por

$$\Sigma = \begin{bmatrix} \frac{11}{144} & -\frac{1}{144} \\ -\frac{1}{144} & \frac{11}{144} \end{bmatrix}.$$

La matriz de covarianzas goza de otras interesantes propiedades de las que en su momento nos ocuparemos.