

I. ESPACIOS DE PROBABILIDAD DISCRETOS

Definición: Un espacio de probabilidad es una terna $(\Omega, \mathcal{A}, P)$ donde $\Omega \neq \emptyset$, $\mathcal{A}$ es una σ -álgebra de Ω , y P una probabilidad en $\mathcal{A}$, i.e., una medida en el espacio medible $(\Omega, \mathcal{A})$ tal que $P(\Omega) = 1$. Llamaremos a los elementos de $\mathcal{A}$ sucesos. Ω es el espacio de las observaciones.

• En particular notar que $P: \mathcal{A} \rightarrow [0, 1]$.

Proposición (Propiedades de P): Sea P una prob. en $(\Omega, \mathcal{A})$. Se gte:

$$1) P(A) + P(A^c) = 1, \quad \forall A \in \mathcal{A}$$

$$2) P(\emptyset) = 0.$$


$$3) A \subseteq B \Rightarrow P(A) \leq P(B), \text{ y en particular } P(B-A) = P(B) - P(A).$$

$$4) P(A \cup B) + P(A \cap B) = P(A) + P(B)$$

$$5) (\text{Desigualdad de Bonferroni, } \sigma\text{-aditividad}) : P\left(\bigcup_{n=1}^{\infty} A_n\right) \leq \sum_{n=1}^{\infty} P(A_n).$$

Definición: Sean $A, B \in \mathcal{A}$, $P(B) \neq 0$. Se llame probabilidad condicionada de A sabiendo que ha ocurrido B (ó respecto a B) a

$$P(A|B) := \frac{P(A \cap B)}{P(B)}$$



• Notar que la aplicación $P_A: \mathcal{A} \rightarrow [0, 1]$
 $B \mapsto P_A(B) := P(B|A)$

es una probabilidad, construida

en el suceso A. Se llame probabilidad condicionada.

Definición: Dos sucesos $A, B \in \mathcal{A}$ se dicen independientes si $P(A \cap B) = P(A) \cdot P(B)$, es decir, si $P(A|B) = P(A)$. En general, $(A_i)_{i \in I} \subset \mathcal{A}$ se dicen independientes si $\forall J \subseteq I$ finito $P(\bigcap_{j \in J} A_j) = \prod_{j \in J} P(A_j)$.

¡OJO!: Para que n sucesos $A_1, \dots, A_n$ sean indep, no basta con que $P(A_1 \cap \dots \cap A_n) = P(A_1) \cdot \dots \cdot P(A_n)$; si no tienen que ser indep. 2 a 2, 3 a 3, $\dots$, $n-1$ a $n-1$ y finally los n .

Teorema (de la probabilidad compuesta): Sean $A_1, \dots, A_n \in \mathcal{A} : P(A_1 \cap \dots \cap A_n) \neq 0$. Entonces

$$P(A_1 \cap \dots \cap A_n) = P(A_1) \cdot P(A_2 | A_1) \cdot P(A_3 | A_1 \cap A_2) \cdot \dots \cdot P(A_n | A_1 \cap \dots \cap A_{n-1}).$$

Teorema (de la probabilidad total): Sean $A_1, \dots, A_n \in \mathcal{A} : \bigcup_{i=1}^n A_i = \Omega, P(A_i) \neq 0, B \in \mathcal{A}$.

$$P(B) = \sum_{i=1}^n P(A_i) \cdot P(B | A_i)$$

Teorema (Bayes): Sean $A_1, \dots, A_n \in \mathcal{A} : \bigcup_{i=1}^n A_i = \Omega, P(A_i) \neq 0, B \in \mathcal{A}, P(B) \neq 0$.

$$P(A_k | B) = \frac{P(A_k) \cdot P(B | A_k)}{\sum_{i=1}^n P(A_i) \cdot P(B | A_i)}$$

Definición: Un espacio medible $(\Omega, \mathcal{A})$ se dice discreto si Ω es finito o infinito numerable y $\mathcal{A} = \mathcal{P}(\Omega)$.

• Una probabilidad P en un esp. de prob. discreto queda determinada por una colección $\{p_\omega : \omega \in \Omega\}$ tal que $P(\{\omega\}) = p_\omega$. Es claro que $P(A) = \sum_{\omega \in A} p_\omega$ y $P(\Omega) = \sum_{\omega \in \Omega} p_\omega$.

COMBINATORIA

Consideres el qto $\Omega = \{1, \dots, n\}$.

- Variaciones con repetición : $VR(n, k) = n^k$: Es el número de

k -uplos $(a_1, \dots, a_k)$, con $a_i \in \{1, \dots, n\}$.

- Variaciones sin repetición y sin orden (o ordinarias) : $VSR(n, k) = \frac{n!}{(n-k)!}$

Es el número de k -uplos $(a_1, \dots, a_k)$ con $a_i \in \{1, \dots, n\}$ pero distintos, i.e. nge
loge de a_i, a_j iguales en la misma upla.

* Caso particular. Permutaciones : $n = k$: $|S_n| = n!$. Es el número de
 n -uplos $(a_1, \dots, a_n)$, con $a_i \in \{1, \dots, n\}$ y distintos, i.e. el número de reordenaciones de $\{1, \dots, n\}$.

- Variaciones sin repetición y orden (o combinaciones) : $VSRO(n, k) = \binom{n}{k}$

Es el número de k -uplos $(a_1, \dots, a_k)$ con $a_i \in \{1, \dots, n\}$, pero distintos y con
 $a_1 < a_2 < \dots < a_k$ (en orden). En otros palabras, es el número de subconjuntos $\{a_1, \dots, a_k\}$,
(con $a_i \in \{1, \dots, n\}$), posibles, i.e. el número de combinaciones de n elementos tomados de k en k .

ESPACIOS DISCRETOS

- La definición clásica de probabilidad de Laplace es que, para sucesos elementales equiprobables, entre n sucesos finitos,

$$P(A) = \frac{\text{casos favorables}}{\text{casos posibles.}}$$

¿Cuál es la descripción matemática de esto? Se trata de $\Omega = \{1, \dots, n\}$, $\mathcal{A} = \mathcal{P}(\Omega)$ y $P(\{i\}) = \frac{1}{n}$.

Definición: En el espacio de probabilidad discreto $(\Omega = \{1, \dots, n\}, \mathcal{A} = \mathcal{P}(\Omega), P(\{i\}) = \frac{1}{n})$, P se dice que es la distribución de probabilidad uniforme discreta.

Definición: Consideremos el espacio vectorial $(\Omega = \{0, \dots, n\}, \mathcal{A} = \mathcal{P}(\Omega))$. Se llame distribución de probabilidad binomial, dados $n \in \mathbb{N}$ y $p \in (0, 1)$, a la probabilidad sobre $(\Omega, \mathcal{A})$

$$b_n(p)(\{k\}) := \binom{n}{k} p^k (1-p)^{n-k}.$$

- La distribución binomial es la que siguen fenómenos aleatorios de éxito-fracaso : extracción de bolas con reposición, sacar 6 veces "2" al tirar 10 veces un dado, ...

Definición: En el espacio vectorial $(\Omega = \{0, \dots, N\}, \mathcal{A} = \mathcal{P}(\Omega))$, dados $N \in \mathbb{N}$, $n \leq N$, $0 \leq k \leq n$, y $C \leq N$, se llame distribución de probabilidad hipergeométrica a

$$H(N, C, n)(\{k\}) := \frac{\binom{C}{k} \binom{N-C}{n-k}}{\binom{N}{n}}.$$

- En la distribución hipergeométrica, N representa el tamaño de la población, n el tamaño de la muestra, C es la cantidad de elementos que cumplen la característica deseada y K es la cantidad de éxito que queremos (la cantidad de individuos que poseen que cumplen la característica).

- Dicha distribución es la que se sigue en extracción de bolas sin reemplazamiento,

Definición: Se llama distribución de probabilidad de Poisson solo el caso ($\Omega = \mathbb{N}_0 = \mathbb{N} \cup \{0\}$, $A = P(\mathbb{N}_0)$), de parámetro $\lambda > 0$, y la denotamos como P_λ , a la que

$$P_\lambda(\{k\}) := e^{-\lambda} \frac{\lambda^k}{k!}.$$

- La distrib. de Poisson se basa en el conteo de los veces que x presenta un fenómeno dentro de un área de oportunidad dada (intervalo de tiempo, e.g.).

- A continuación se describen las generalizaciones de la dist. hipergeométrica y binomial:

Definición: Sean $N \in \mathbb{N}$, $n \leq N$, $0 \leq k_1 \leq n_1, \dots, 0 \leq k_r \leq n_r$, $r \in \mathbb{N}$. Se llama distribución de probabilidad hipergeométrica múltiple, definida solo el caso viable

($\Omega = \{(k_1, \dots, k_r) \in \prod_{i=1}^r \{0, \dots, n_i\} : \sum_{i=1}^r k_i = n\}$, $A = P(\Omega)$) a

$$P(k_1, \dots, k_r) := \frac{\prod_{i=1}^r \binom{n_i}{k_i}}{\binom{N}{n}}$$

- Es la prob. de sacar k_1 bolas del primer color que tiene n_1 bolas, $\dots$, k_r bolas del color r -ésimo que tiene n_r bolas; y $N = n_1 + \dots + n_r$, con reemplazamiento.

Definición: Sean $n, N \in \mathbb{N}$, $k_1 + \dots + k_r = n$, $p_i = \frac{n_i}{N}$. Se llame distribución de probabilidad multinomial $M(n; p_1, \dots, p_r)$, definida en $(\Omega = \{(k_1, \dots, k_r) \in \mathbb{N}_0^r : \sum k_i = n\}, \mathcal{A} = \mathcal{P}(\Omega))$ a la probabilidad

$$P(k_1, \dots, k_r) := \binom{n}{k_1, \dots, k_r} p_1^{k_1} \dots p_r^{k_r},$$

donde
$$\binom{n}{k_1, \dots, k_r} = \frac{n!}{k_1! \dots k_r!}.$$

• Es la seguida en el ejemplo anterior pero sin reemplazando.

II. VARIABLES ALEATORIAS

Definición: Sean $(\Omega, \mathcal{A})$ y $(\Omega', \mathcal{A}')$ dos espacios medibles. En probabilidad, llamaremos variables aleatorias (v.a.) a las funciones medibles $X: (\Omega, \mathcal{A}) \rightarrow (\Omega', \mathcal{A}')$, i.e., funciones tales que $X^{-1}(\mathcal{A}') \subseteq \mathcal{A}$. Si $(\Omega', \mathcal{A}') = (\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n) = \mathcal{B}_n)$, diremos que X es una v.a. n -dimensional o que es una función Borel-medible. En el caso $n=1$, X se dice variable aleatoria real (v.a.r.).

Proposición: Se cumple

- 1) Toda función constante es medible
- 2) La composición de medibles es medible
- 3) Las aplicaciones continuas $X: (\Omega, \mathcal{B}(\Omega)) \rightarrow (\Omega', \mathcal{B}(\Omega'))$ son medibles.
- 4) Las funciones crecientes $\mathbb{R} \rightarrow \mathbb{R}$ son Borel-medibles
- 5) Las proyecciones de un espacio producto en sus factores (con la σ -alg. producto) son medibles.
- 6) $(\Omega, \mathcal{A}) \xrightarrow{X=(X_1, \dots, X_n)} \mathbb{R}^n$ es medible $\iff X_i$ medible $\forall i$.

Definición: Sea $(\Omega, \mathcal{A}, P)$ un esp. de prob., y $X: \Omega \rightarrow \mathbb{R}$ Borel-medible. Llamaremos esperanza o media de X a $E_p(X) = E(X) = EX := \int X dP$, cuando exista.

• Delta de Dirac: Sea $(\Omega, \mathcal{A})$ medible, y $\omega \in \Omega$. La función de conjuntos

$$\begin{aligned} \delta_\omega: \mathcal{A} &\longrightarrow [0, \infty] \\ A &\longmapsto \delta_\omega(A) := \begin{cases} 1 & \text{si } \omega \in A \\ 0 & \text{f} \end{cases} \end{aligned}$$

es una probabilidad, llamada probabilidad de Dirac o degenerada. Si $X: \Omega \rightarrow \mathbb{R}$ v.a.,
 $\int f d\delta_\omega = f(\omega)$.

• Medida de contar (o cardinal): En $(\Omega, \mathcal{A})$ espacio medible, $A \in \mathcal{A}$, la función $\mu(A) := \#A$
 es la medida de contar. Si $\Omega = \mathbb{N}$, las funciones $f: \mathbb{N} = \Omega \rightarrow \mathbb{R}$ se identifican con las
 sucesiones (x_n) . De dicho espacio, con la medida de contar, se extraen las funciones p -integrables
 $\ell_p \equiv$ sucesiones p -sumables. Para $p=1$, $f: \mathbb{N} \rightarrow \mathbb{R}$ μ -int $\Leftrightarrow \sum_{n=1}^{\infty} |f(n)| < \infty$, y
 en este caso $\int_{\mathbb{N}} f d\mu = \sum f(n)$.

• Si μ es una medida sobre $(\Omega, \mathcal{A})$, y $c > 0$, $c\mu$ es otra medida: $(c\mu)(A) = c \cdot \mu(A)$
 y $\int f d(c\mu) = c \int f d\mu$.

• Si (μ_n) es una suc. de medidas sobre $(\Omega, \mathcal{A})$, $\sum_n \mu_n$ es otra medida: $(\sum_n \mu_n)(A) := \sum_n \mu_n(A)$ y
 $\int f d(\sum_n \mu_n) = \sum_n \int f d\mu_n$.

• Si (P_n) suc. de probabilidades sobre $(\Omega, \mathcal{A})$ y (c_n) suc. de números reales tales que $\sum c_n = 1$, entonces
 $P := \sum_n c_n P_n$ es una probabilidad, y si X v.a.r, $E_P(X) = \sum_n c_n E_{P_n}(X)$.

• Si μ es una medida en $(\Omega, \mathcal{A})$, y fijamos $A \in \mathcal{A}$, entonces

$$\mu|_A : \mathcal{A} \longrightarrow [0, \infty]$$

$$B \longmapsto \mu|_A(B) := \mu(A \cap B)$$

$$\mu|_A = \mu(A \cap \cdot)$$

es una medida en $\mathcal{A}$, y $\int f d\mu|_A = \int_A f d\mu$.

• Notar que la probabilidad condicionada $P_A(B) := P(B|A)$ verifica $P_A = \frac{1}{P(A)} \cdot P|_A$. Así,

Definición: Sea $(\Omega, \mathcal{X}, P)$ exp. prob., $A \in \mathcal{X}$ no nulo, y X una v.a. Se llama esperanza condicional de X respecto a A a

$$E_P(X|A) := E_{P_A}(X) = \frac{1}{P(A)} \int_A X dP$$

Importante: $E(X)$ se interpreta como el valor medio, el valor esperado de X en una larga serie de pruebas del experimento; y $E(X|A)$ lo mismo pero solo teniendo en cuenta aquellos en los que ha ocurrido A .

Teorema (de la medida imagen): Sea $(\Omega, \mathcal{A}, \mu)$ un exp. medido y $X: (\Omega, \mathcal{A}, \mu) \rightarrow (\Omega', \mathcal{A}')$ una v.a. Podemos definir una medida en $(\Omega', \mathcal{A}')$ "llevándonos μ a $(\Omega', \mathcal{A}')$ ", definiendo

$$\mu^X : \mathcal{A}' \longrightarrow [0, \infty]$$

$$A' \longmapsto \mu^X(A') := \mu(X^{-1}(A'))$$

es en efecto una medida en $(\Omega', \mathcal{A}')$, llamada medida imagen de μ por X . Si $f: (\Omega', \mathcal{A}') \rightarrow \mathbb{R}$,

$$\int f d\mu^X = \int f \circ X d\mu$$

Definición: Sea $(\Omega, \mathcal{A}, P)$ un esp. prob., y $X: (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B})$. Llamaremos distribución de probabilidad de X a la medida imagen P^X .

• El TM1 dice que $E_{P^X}(f) = E_P(f \circ X)$.

Definición: Sea X v.a.r. en $(\Omega, \mathcal{A}, P)$. Se llama función de distribución de X a

$$F_X: \mathbb{R} \rightarrow [0, 1]$$

$$x \mapsto F_X(x) := P(X \leq x) = P^X((-\infty, x]).$$

• F_X es crec. y cont. a la derecha. En particular, F_X es la func. de distribución de la medida de Lebesgue-Stieltjes P^X .

Definición: Sea X v.a.r. Se llama varianza de X a $\text{Var } X := E[(X - E(X))^2]$.

$$\text{Var } X = E(X^2) - [E(X)]^2.$$

Teorema (de la Carga): Sea μ una medida en $(\Omega, \mathcal{A})$, y $h: \Omega \rightarrow \mathbb{R}$, $h \geq 0$. Entonces la func. de carga sobre $\mathcal{A}$ $\lambda(A) := \int_A h d\mu$ es una medida sobre $\mathcal{A}$, y $\lambda \ll \mu$ (λ se dice abs. cont. resp. μ o que λ está dominada por μ). Dicha h recibe el nombre de densidad de λ resp. μ .

Definición: Sea $X: (\Omega, \mathcal{A}, P) \rightarrow (\Omega', \mathcal{A}', \mu')$. Se dice que X tiene densidad h respecto μ' si h es una derivada r.n. de P^X resp μ' , i.e., $h = \frac{dP^X}{d\mu'}$. Si

$X: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}$ es una v.a.r., se dice que X tiene densidad h si tiene densidad h resp. la medida de Lebesgue m , i.e., si $h = \frac{dP^X}{dm}$. Se dice que X es absolutamente continua. Se dice también que h es la función de densidad de X .

• CASO U. CONT:

• En el caso en el que X v.a.r. tenga densidad h ,

$$E(X) = \int_{-\infty}^{\infty} x h(x) dx, \quad \text{Var}(X) = \int_{-\infty}^{\infty} (x - E(X))^2 h(x) dx,$$

$$F_X(x) = P(X \leq x) = \int_{-\infty}^x h(t) dt.$$

Definición: Sea $(\Omega, \mathcal{A}, P)$ esp. de prob. Se llama función de probabilidad a

$$\begin{aligned} f: \Omega &\rightarrow [0, 1] \\ \omega &\mapsto f(\omega) := P(\omega) \end{aligned}$$

CARACTERIZACIÓN

Si $X: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{N}_0 = \mathbb{N} \cup \{0\}$ es una v.a., su distribución $P^X(\text{en } (\mathbb{N}_0, P(\mathbb{N}_0)))$ queda determinado por su función de probabilidad

$$\begin{aligned} f: \mathbb{N}_0 &\rightarrow [0, 1] \\ n &\mapsto \underline{f(n) = P^X(n) = P(X=n)}. \end{aligned}$$

Si μ es la medida de cuenta, $f = \frac{dP^X}{d\mu}$ (f es la densidad de X resp. μ), p.e. en $\mathbb{A} \subseteq \mathbb{N}_0$, $P^X(\mathbb{A}) = \sum_{n \in \mathbb{A}} f(n) = \int_{\mathbb{A}} f d\mu$. Adici.

$$E(X) = \sum_{n=0}^{\infty} n f(n), \quad \text{Var } X = \sum_{n=0}^{\infty} (n - E(X))^2 f(n), \quad F_X(x) = \begin{cases} f(0) + \dots + f(n) & x \in [n, n+1) \\ 0 & x < 0 \end{cases}$$

Teorema (de cambio de variables): Sean U, V abertos de $\mathbb{R}^n$ y $T: U \subseteq \mathbb{R}^n \rightarrow V \subseteq \mathbb{R}^n$ un difeomorfismo.

Sea $J_T = \det \left(\frac{\partial T_i}{\partial x_j} \right)$ el jacobiano de T . Entonces, para $B \in \mathcal{B}(U)$,

$$m(T(B)) = \int_B |J_T| \, d\mu \quad \left(\text{i.e., } |J_T| = \frac{d\mu^{T^{-1}}}{d\mu} \right)$$

y si $f: V \rightarrow \mathbb{R}$ Borel-medible,

$$\int_V f \, d\mu = \int_U (f \circ T) |J_T| \, d\mu.$$

Teorema (de transformación de variables): Sean U, V abertos de $\mathbb{R}^n$ y $T: U \subseteq \mathbb{R}^n \rightarrow V \subseteq \mathbb{R}^n$ un difeomorfismo. Sea $X: (\Omega, \mathcal{A}, P) \rightarrow U$ una v.a. (n-dimensional) de densidad f_X

(i.e., $f_X = \frac{dP^X}{d\mu}$). Entonces la v.a. $Y := T \circ X$ tiene densidad

$$f_Y(y) = \frac{dP^{T \circ X}}{d\mu} = (f \circ T^{-1})(y) \cdot |J_{T^{-1}}(y)|.$$

y $\forall B \in \mathcal{B}(V)$,

$$\mu^T(B) = \mu(T^{-1}(B)) = \int_{T^{-1}(B)} d\mu = \int_B |J_{T^{-1}}(y)| \, d\mu.$$

$$\text{i.e., } |J_{T^{-1}}| = \frac{d\mu^T}{d\mu}.$$

Teorema (clásico de la medida producto): Sean $(\Omega_1, \mathcal{A}_1, \mu_1), (\Omega_2, \mathcal{A}_2, \mu_2)$ dos espacios de medida σ -finitos. Entonces existe una única medida μ en $(\Omega_1 \times \Omega_2, \mathcal{A}_1 \otimes \mathcal{A}_2)$ tal que $\forall E \in \mathcal{A}$,

$$\mu(E) = \int \mu_2(E_{\omega_1}) d\mu_1 = \int \mu_1(E_{\omega_2}) d\mu_2$$

y para los productos de medibles $\mu(A_1 \times A_2) = \mu_1(A_1) \cdot \mu_2(A_2)$. Además, μ es σ -finita, y si μ_1 y μ_2 lo son.

Teorema (clásico de FUBINI): Si $f: \Omega_1 \times \Omega_2 \rightarrow \overline{\mathbb{R}}$ es Borel medible y existe $\int f d\mu$,

$$\int f d\mu = \int_{\Omega_1} \left(\int f d\mu_2 \right) d\mu_1 = \int_{\Omega_2} \left(\int f d\mu_1 \right) d\mu_2$$


y los integrales iterados existen c.s.

DISTRIBUCIONES IMPORTANTES

Definición: Sea $[a, b] \subseteq \mathbb{R}$. Se llama distribución uniforme continua sobre $[a, b]$ a la probabilidad en $\mathbb{R}$ que queda definida por la función de densidad

$$f(x) = \frac{1}{b-a} I_{[a,b]}(x)$$

(en general, con $B \in \mathcal{B}_1$, $m(B) > 0$, la distr. unif. es la prob. def. por la func. de densidad $f(x) = \frac{1}{m(B)} I_B$)



Definición: Se dice que una v.a.r. X tiene distribución de probabilidad normal

$P^X = N(\mu, \sigma^2)$, donde μ es la media y σ^2 la varianza; si su función de densidad es

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}$$

• La distribución normal estándar $N(0,1)$ es una probabilidad que queda definida en $(\mathbb{R}, \mathcal{B}_\mathbb{R})$ mediante su densidad rep. llamada de Laplace

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2}$$



"Campana de Gauss".

Definición: Una v.a.r. X tiene distribución gamma $X \sim \mathcal{G}(\alpha, \beta)$ de parámetros $\alpha, \beta > 0$ si tiene como función de densidad

$$f(x) = \frac{1}{\Gamma(\alpha)\beta^\alpha} x^{\alpha-1} e^{-\frac{x}{\beta}} I_{(0,\infty)}(x)$$

- Si $\alpha \in \mathbb{N}$, $\mathcal{G}(\alpha, \beta)$ se llama distribución de Erlang
- $\mathcal{G}(1, \beta)$ es la distribución exponencial de parámetro β , $E(\beta)$, $f(x) = \frac{1}{\beta} e^{-x/\beta} I_{(0,\infty)}(x)$.
- Si $n \in \mathbb{N}$, y $X \sim \mathcal{G}(\frac{n}{2}, 2)$, se dice que X tiene distribución chi-cuadrado con n grados de libertad, $X \sim \chi^2(n)$.

MOMENTOS Y DESIGUALDADES

Definición: Sea $X: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}$ v.a.r. y $k > 0$. Llamaremos momento de orden k a $E(X^k)$, momento absoluto de orden k a $E(|X|^k)$ y momento central de orden k a $E[(X - EX)^k]$.

• La media es el momento de orden 1 de X , y la varianza el momento central de orden 2 de X .

Proposición:

- 1) Si X tiene momentos de orden $k < \infty \Rightarrow$ tiene momentos de orden $j, 0 < j \leq k$.
- 2) Si X tiene momentos finitos de orden $n-1$, y existe el momento de orden n , entonces el momento central de orden n es

$$E[(X - EX)^n] = \sum_{k=0}^n (-1)^{n-k} \binom{n}{k} E(X^k) E(X)^{n-k}$$

Proposición (desigualdad de Markov): Si X v.a.r., $K, \alpha > 0$,

$$P(|X| \geq \alpha) \leq \alpha^{-K} E(|X|^K)$$

Proposición (Desigualdad de Chebyshev): Sea X v.a.r. con media μ finita y varianza σ^2 finita, y $k > 0$. Entonces

$$P(|X - \mu| \geq k\sigma) \leq \frac{1}{k^2}$$

Es decir, la prob. de encontrar valores de X que disten más de la media más que k desviaciones típicas es $\leq \frac{1}{k^2}$.

Proposition (Inégalité de Cauchy-Schwarz) : Soient X, Y var. 2-intégrables en $(\Omega, \mathcal{A}, P)$. Et.

$$E(|XY|) \leq \sqrt{E(X^2)} \sqrt{E(Y^2)}$$

Définition : Soient $X, Y \in \mathcal{L}^2(\Omega, \mathcal{A}, P)$. Soit la covariance de X et Y a

$$\text{Cov}(X, Y) := E[(X - EX)(Y - EY)]$$

Définition : Soient coefficient de corrélation (de Pearson) entre X et Y a

$$\rho(X, Y) := \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var } X} \sqrt{\text{Var } Y}}$$

• La desigualdad CS prouve que $\rho(X, X)$ est bien déf. ($\exists$ l'absol.)

• $\text{Cov}(X, Y) = E(XY) - E(X)E(Y)$

• $\rho(X, Y) \in [-1, 1]$

• $\text{Cov}(aX + b, cY + d) = ac \text{Cov}(X, Y)$; $\rho(aX + b, cY + d) = \rho(X, Y)$.

• $\text{Cov}(aX + b, cY + d) = ac \text{Cov}(X, Y)$; $\rho(aX + b, cY + d) = \rho(X, Y)$.

Définition : Soit $X = (X_1, \dots, X_n)$ une v.a. n -dim. en $(\Omega, \mathcal{A}, P)$, $X \in \mathcal{L}^2(\Omega, \mathcal{A}, P)$.

Soit la matrice de covariances de X a

$$\text{Cov } X := \left(\text{Cov}(X_i, X_j) \right)_{i, j=1, \dots, n} = E \left[(X - EX)(X - EX)^T \right]$$

Lema: Sea X v.a.r. con densidad f , e $Y := a + bX$, ($b \neq 0$). Entonces Y tiene densidad $\frac{1}{|b|} f\left(\frac{y-a}{b}\right)$.

Proposición:

$$1) X \sim N(\mu, \sigma^2) \Rightarrow a + bX \sim N(a + b\mu, b^2\sigma^2) \quad (a, b \in \mathbb{R}, b \neq 0)$$

$$2) Z \sim N(0, 1) \Rightarrow \mu + \sigma Z \sim N(\mu, \sigma^2), \quad (\mu \in \mathbb{R}, \sigma > 0)$$

$$3) X \sim N(\mu, \sigma^2) \Rightarrow \frac{X - \mu}{\sigma} \sim N(0, 1). \text{ A dicho hecho se le}$$

conoce como tipificación de $N(\mu, \sigma^2)$.

Definición: Una clase $\mathcal{C} \subset \mathcal{P}(\Omega)$ se dice π -sistema si $A_1, \dots, A_n \in \mathcal{C} \Rightarrow \bigcap_{i=1}^n A_i \in \mathcal{C}$.

Definición: Una clase $\mathcal{D}$ se dice σ -sistema si

$$i) \Omega \in \mathcal{D}$$

$$ii) D_1, D_2 \in \mathcal{D}, D_1 \subset D_2 \Rightarrow D_2 - D_1 \in \mathcal{D}$$

$$iii) D_1 \subset D_2 \subset D_3 \subset \dots \text{ suc. creciente en } \mathcal{D} \Rightarrow \bigcup_n D_n \in \mathcal{D}.$$

Teorema (Dynkin): Si $\mathcal{C}$ es un π -sistema en Ω , el σ -sistema engendrado por $\mathcal{C}$ (el menor σ -sistema que contiene a $\mathcal{C}$) coincide con la σ -álgebra generada por $\mathcal{C}$ (línea de hechos), i.e.,

$$d(\mathcal{C}) = \sigma(\mathcal{C}).$$

Teorema: Sean $(\Omega_i, \mathcal{A}_i, P_i)$ esp. de prob. y condens $(\Omega = \prod \Omega_i, \mathcal{A} = \bigotimes \mathcal{A}_i, P = \prod P_i)$ el esp. de prob. producto. Entonces, las proyecciones $\pi_i: (\Omega, \mathcal{A}, P) \rightarrow (\Omega_i, \mathcal{A}_i, P_i), \pi_i(\omega) = \omega_i$ son independientes y $P^{\pi_i} = P_i$.

Teorema: Sean $(\Omega_n, \mathcal{A}_n)$ esp. medibles y $X_n: (\Omega, \mathcal{A}, P) \rightarrow (\Omega_n, \mathcal{A}_n)$ v.a. Para cada $n \in \mathbb{N}$, sea la v.a. $Y_n: (\Omega^{\mathbb{N}} := \prod_{i=1}^{\infty} \Omega_i, \mathcal{A}^{\mathbb{N}} = \bigotimes_{i=1}^{\infty} \mathcal{A}_i, P^{\mathbb{N}} = \prod P_i) \rightarrow (\Omega_n, \mathcal{A}_n)$, $Y_n(\omega_1, \omega_2, \dots) := X_n(\omega_n)$. Entonces Y_n tiene respecto a $P^{\mathbb{N}}$ la misma distribución que X_n resp. P ; y las Y_n son indep.

Teorema (Criterio de indep. con densidades): Sean $X_i: (\Omega, \mathcal{A}, P) \rightarrow (\Omega_i, \mathcal{A}_i, \mu_i)$, $i=1, \dots, n$ v.a., y μ_i una medida σ -finita. Sean $X = (X_1, \dots, X_n)$ y $\mu = \mu_1 \times \dots \times \mu_n$.

1) Si $f = \frac{dP^X}{d\mu} \Rightarrow X_i$ tiene resp. μ_i densidad

$$\frac{dP^{X_i}}{d\mu_i} = f_i(\omega_i) = \int_{\prod_{j \neq i} \Omega_j} f(\omega_1, \dots, \omega_n) d\left(\prod_{j \neq i} \mu_j\right)$$

$$2) \left[\text{Si } f_i = \frac{dP^{X_i}}{d\mu_i}, \text{ entonces} \right] (X_i) \text{ son indep.} \Leftrightarrow f = \prod_{i=1}^n f_i$$

Definición: Dichas f_i se llaman densidades marginales i -ésimas.

Definición: Dos v.a. X, Y se dicen incorreladas si $\text{Cor}(X, Y) = 0$.

Proposición: Si $X_1, \dots, X_n$ son v.a. reals o complejas integrables independientes, entonces

$$E(X_1 \cdots X_n) = E(X_1) \cdots E(X_n)$$

y si tienen varianzas finitas,

$$\text{Var}(X_1 + \dots + X_n) = \text{Var}(X_1) + \dots + \text{Var}(X_n).$$

Proposición: X, Y v.a.r. independientes (e integrables) $\Rightarrow X, Y$ incorreladas.

¡OJO! : En general $\nLeftarrow$.

Proposición: Si $X_1, \dots, X_n$ v.a. independientes e idénticamente distribuidas, con distribución común $b_1(p)$ de Bernoulli, de parámetro $p \Rightarrow$ la v.a. $S_n = \sum X_i$ sigue una distribución binomial $b_n(p)$.

¡IMPORTANTE: X, Y iid $\Rightarrow E[X] = E[Y]$ y $\text{Var}[X] = \text{Var}[Y]$

IV: ESPERANZA CONDICIONAL

Teorema (Radon-Nikodym): Sean λ, μ medidas σ -finitas sobre $(\Omega, \mathcal{A})$.

$$\lambda \ll \mu \iff \exists (\mu\text{-c.s.}) h: \Omega \rightarrow \mathbb{R}, h \geq 0 : \lambda(A) = \int_A h d\mu \quad \forall A \in \mathcal{A}.$$

Teorema (Existencia de la Esperanza Condicional): Sea $X: (\Omega, \mathcal{A}) \rightarrow (\Omega', \mathcal{A}')$ v.a., $Y: (\Omega, \mathcal{A}) \rightarrow \mathbb{R}$,
 $h(Y \geq 0 \text{ (o } E(Y) < \infty)) \Rightarrow \exists (P^X\text{-c.s.}) g: (\Omega', \mathcal{A}') \rightarrow \mathbb{R}, g \geq 0 \text{ (o } E(g) < \infty) :$

$$\int_{X^{-1}(A')} Y dP = \int_{A'} g dP^X$$

$$\begin{array}{ccc} (\Omega, \mathcal{A}) & \xrightarrow{X} & (\Omega', \mathcal{A}') \\ Y \searrow & & \swarrow \exists g \\ & \mathbb{R} & \end{array}$$

Definición: Llamaremos esperanza condicional de Y respecto X a dicho g del Th, y la denotaremos $E(Y|X)$.

• Notar que $E(Y|X)$ es, más bien, una clase de equiv. de funciones que coinciden P^X -c.s.

Definición: Se llama probabilidad condicional de A respecto X a $P(A|X) := E(I_A|X)$.


• Recordar que se sabe que $E(X|X) = \frac{1}{P(A)} \int_A X dP$.

Denotemos $g(x) = E(Y|X)(x) \stackrel{\text{not}}{=} E(Y|X=x)$.

Definición: Si $Y = (Y_1, \dots, Y_n)$ v.a. n -dim, definamos $E(Y|X) := (E(Y_1|X), \dots, E(Y_n|X))$.

Definición: Sea $\mathcal{B}$ una sub- σ -álgebra de $\mathcal{A}$, $Y: \Omega \rightarrow \mathbb{R}$, $Y \geq 0$. Definiremos esperanza condicional de Y respecto $\mathcal{B}$, y la denotaremos $E(Y|\mathcal{B})$, a toda función $\Omega \rightarrow \mathbb{R}_{\geq 0}$ ($\int E(Y) < \infty$) $\mathcal{B}$ -medible.

$$\int_{\mathcal{B}} Y \, dP = \int_{\mathcal{B}} E(Y|\mathcal{B}) \, dP \quad \forall \mathcal{B} \in \mathcal{B}$$



Definición: Se llama operador condicional de $A \in \mathcal{A}$ respecto $\mathcal{B}$, a $P(A|\mathcal{B}) := E(I_A|\mathcal{B})$.

Nota: La existencia de $E(Y|\mathcal{B})$ queda asegurada por el Th Exist.

$$\int_{\mathcal{B}} P(A|\mathcal{B}) \, dP = P(A \cap \mathcal{B}).$$


La operador condicional recupera la def clásica de probs. condicional $P(A|B) = \frac{P(A \cap B)}{P(B)}$.

$$Y \text{ v.a.r. } \mathcal{B}\text{-medible} \Rightarrow E(Y|\mathcal{B}) = Y$$

$$f: (\Omega', \mathcal{A}') \rightarrow \mathbb{R} \text{ v.a.r. } \geq 0 \text{ } P^X\text{-int.} \Rightarrow E(f \circ X|X) = f.$$

Proposición: Sea $X: (\Omega, \mathcal{A}) \rightarrow (\Omega', \mathcal{A}')$ y $\mathcal{B} = X^{-1}(\mathcal{A}')$ una sub- σ -álgebra de $\mathcal{A}$, y $h: \Omega \rightarrow \mathbb{R}$.

$$h: (\Omega, \mathcal{B}) \rightarrow \mathbb{R} \text{ medible} \iff \exists f: (\Omega', \mathcal{A}') \rightarrow \mathbb{R} \text{ v.a. : } h = f \circ X$$



Corolario: Sea $X: (\Omega, \mathcal{A}) \rightarrow (\Omega', \mathcal{A}')$, $Y: (\Omega, \mathcal{A}) \rightarrow \mathbb{R}$ v.a.r. ≥ 0 ($\int E(Y) < \infty$), y $\mathcal{B} = X^{-1}(\mathcal{A}')$.

Entonces la aplicación $g \in E(Y|X) \rightarrow g \circ X \in E(Y|\mathcal{B})$ es epigeométrica (g está en el σ -álgebra de $\mathcal{B}$, y $g \circ X$ es $\mathcal{B}$ -medible). Por lo cual

$$E(Y|\mathcal{B}) = E(Y|X) \circ X.$$

Proposición (Propiedades): Sean Y, Y_1, Y_2 v.a.r. ≥ 0 (o con esperanza finita).

$$1) E_P(Y) = E_{P^X}[E(Y|X)]$$

$$2) (\text{Monotonía}): Y_1 \leq Y_2 \Rightarrow E(Y_1|X) \leq E(Y_2|X) \quad P^X\text{-c.s.}$$

$$3) (\text{Linealidad}): E(a_1 Y_1 + a_2 Y_2 | X) = a_1 E(Y_1|X) + a_2 E(Y_2|X) \quad P^X\text{-c.s.}, \quad a_1, a_2 \in \mathbb{R}.$$

Teorema (de la Convergencia Monotona para la Exp. Cond.): Sea $(Y_n) \uparrow Y$ una suc. creciente de v.a.r. $\Omega \rightarrow \mathbb{R}$, entonces $(E(Y_n|X))$ es una suc. de v.a.r. crecientes que convergen a $E(Y|X)$.

Corolarios:

$$1) \text{ Si } (Y_n) \geq 0, \Rightarrow E(\sum Y_n | X) = \sum E(Y_n | X) \quad , \quad P^X\text{-c.s.}$$

$$2) (A_n) \subset \mathcal{A} \text{ disjuntos} \Rightarrow P(\bigcup_n A_n | X) = \sum_n P(A_n | X) \quad , \quad P^X\text{-c.s.}$$

Teorema (de la Convergencia Dominada para la Exp. Cond.): Sean (Y_n) v.a.r. $\Omega \rightarrow \mathbb{R}$. Si existe una v.a.r. $Z: \Omega \rightarrow \mathbb{R}$ con esperanza finita: $|Y_n| \leq Z \quad \forall n \quad (P\text{-c.s.})$, y $Y_n \xrightarrow[P]{P^X\text{-c.s.}} Y$
 $\Rightarrow E(Y_n | X) \xrightarrow[P]{P^X\text{-c.s.}} E(Y | X)$.

Teorema:

1) Sea $\mathcal{B} \subseteq \mathcal{A}$ sub- σ -álgebra, $Y: (\Omega, \mathcal{A}) \rightarrow \mathbb{R}$, $Z: (\Omega, \mathcal{B}) \rightarrow \mathbb{R}$ v.a. Si $Y, YZ \in \mathcal{L}^1$,

$$E(YZ | \mathcal{B}) = Z \cdot E(Y | \mathcal{B}) \quad P\text{-c.s.}$$

2) $f: (\mathcal{X}, \mathcal{X}') \rightarrow \mathbb{R}$ v.a., $Y, Y(f \circ X)$ son v.a.r. $\in \mathcal{L}^1$,

$$E(Y(f \circ X) | X) = f \cdot E(Y | X) \quad P^X\text{-c.s.}$$

Proposition : Soit $X: (\Omega, \mathcal{F}, P) \longrightarrow (\mathbb{R}^d, \mathcal{B}^d, P^X)$, $Y: (\Omega, \mathcal{F}, P) \longrightarrow \mathbb{R}$ v.c.r. Ets

$$E(Y|X=x) = \frac{1}{P(X=x)} \int_{\{X=x\}} Y dP.$$

Proposition : Si X, Y sont v.c.r. indépendants, $E(XY|X=x) = E(X|X=x) \cdot E(Y|X=x)$.

V: DISTRIBUCIÓN CONDICIONAL

Definición: Sea X v.a., Y v.a.r. ^{con cond. reg.} Se llame función de distribución condicional regular de Y resp. X a toda

$$\begin{array}{ccc} (\Omega, \mathcal{A}, P) & \xrightarrow{X} & (\Omega', \mathcal{A}', P^X) \\ & \searrow Y & \\ & & \mathbb{R} \end{array}$$

aplicación $F: \Omega' \times \mathbb{R} \rightarrow \mathbb{R}$ que verifique:

- i) $\forall x \in \Omega', F(x, \cdot)$ es una f.d. de $\mathbb{R}$
- ii) $\forall y \in \mathbb{R}, F(\cdot, y)$ es una versión de $P(Y \leq y | X)$.

Teorema (Existencia de la función de distr. cond. reg.): Para cualquier v.a.r. $Y: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}$ existe una función de distribución condicional regular de Y resp. X .

Definición: Sean X, Y v.a. como en el diag. Se llame probabilidad condicional regular de Y resp. X a toda aplicación $Q \equiv P^{Y|X}: \Omega' \times \mathcal{A}_1 \rightarrow [0,1]$ que verifique:

$$\begin{array}{ccc} (\Omega, \mathcal{A}, P) & \xrightarrow{X} & (\Omega', \mathcal{A}', P^X) \\ & \searrow Y & \\ & & (\Omega_1, \mathcal{A}_1, P^{Y|X=x}) \end{array}$$

- i) $\forall x \in \Omega', Q(x, \cdot) = P^{Y|X=x}$ es una probab. en $(\Omega_1, \mathcal{A}_1)$, que recibe el nombre de distribución condicional de Y resp. X

- ii) $\forall A_1 \in \mathcal{A}_1, Q(\cdot, A_1) = P^{Y|X=\cdot}(A_1)$ es una versión de $P(Y \in A_1 | X)$.

Notar que una prob. cond. regular es en particular un retículo de transición.

Teorema (Existencia de una probabilidad condicional reg.): Para cualquier v.a.r. $Y: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}$ existe una probab. cond. reg. de Y resp. X .

PROBLEMA DE REGRESIÓN

Teorema: Sea $1 \leq p < \infty$, $Y \in L_p(\Omega, \mathcal{A}, P; \mathbb{R})$, $\mathcal{B} \subseteq \mathcal{A}$ σ -álgebra.

$\Rightarrow E(Y|\mathcal{B}) \in L_p(\Omega, \mathcal{A}, P; \mathbb{R})$ y $\|E(Y|\mathcal{B})\|_p \leq \|Y\|_p$. Además para $p=2$,

$$\|Y - E(Y|\mathcal{B})\|_2 \leq \|Y - Z\|_2 \quad \forall Z \in L_2(\Omega, \mathcal{B}, P; \mathbb{R})$$

• Problema general de regresión: Dados $(\Omega, \mathcal{A}, P) \xrightarrow{X} (\mathcal{N}, \mathcal{N})$
 $\searrow Y \rightarrow \mathbb{R} \xleftarrow{\exists f?}$

$\exists f: Y = f \circ X$? En general no! Entonces, ¿cuál es la mejor $f: (\mathcal{N}, \mathcal{N}) \rightarrow \mathbb{R}$

tal que $Y \approx f \circ X$ en el sentido de los mínimos cuadrados, i.e., ¿cuál es la f que hace mínima la expresión $\|Y - f \circ X\|_2$?

Si $\mathcal{B} = X^{-1}(\mathcal{N})$, $E(Y|\mathcal{B}) = E(Y|X) \circ X$, y el Teorema anterior dice que

$$\|Y - E(Y|X) \circ X\|_2 \leq \|Y - f \circ X\|_2 \quad \forall f \in L^2$$

con lo cual $f = E(Y|X)$. Si X es v.a.r., se llama curva de regresión a

$$E(Y|X): \mathbb{R} \rightarrow \mathbb{R}$$
$$x \mapsto E(Y|X=x).$$

FÓRMULAS IMPORTANTES

I

$$P(B) = \sum_{i=1}^n P(A_i) \cdot P(B|A_i)$$

$$P(A_k|B) = \frac{P(A_k) \cdot P(B|A_k)}{\sum P(A_i) \cdot P(B|A_i)}$$

$$b_n(p)(\{k\}) = \binom{n}{k} p^k (1-p)^{n-k}$$

$$H(N, C, n)(\{k\}) = \frac{\binom{C}{k} \binom{N-C}{n-k}}{\binom{N}{n}}$$

$$P(k_1, \dots, k_r) = \binom{n}{k_1, \dots, k_r} p_1^{k_1} \dots p_r^{k_r}$$

$$P(k_1, \dots, k_r) = \frac{\prod \binom{n_i}{k_i}}{\binom{N}{n}}$$

II

CASO ABU. CONT.

$X: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}$ v.a.r.

$$h = \frac{dP^X}{d\mu}$$

$$E(X) = \int_{\mathbb{R}} x h(x) dx$$

$$F_X(x) = \int_{-\infty}^x h(t) dt$$

$$Var X = \int_{\mathbb{R}} (x - EX)^2 h(x) dx$$

CASO DISCRETO

$X: (\Omega, \mathcal{A}, P) \rightarrow \mathbb{N}_0$ v.a.

f función de prob.: $f(n) = P(X=n) = P^X(n)$

$f(x) = \frac{dP^X}{d\mu} = P^X(h \cdot \delta)$
 $\leftarrow$ med. de conteo

$$E(X) = \sum_{n=0}^{\infty} n f(n)$$

$$Var X = \sum_{n=0}^{\infty} (n - EX)^2 f(n)$$

$$F_X(x) = \begin{cases} f(0) + \dots + f(n) & x \in [n, n+1) \\ 0 & x < 0 \end{cases}$$

$$Y = T \circ X$$

Th (Transf. Var): $S_{\mathbb{R}}(\Omega, \mathcal{A}, P) \xrightarrow{X} U \subseteq \mathbb{R}^n \xrightarrow{T} V \subseteq \mathbb{R}^n$, f_X dens. de X

$$f_X = \frac{dP^X}{d\mu}$$

$$\Rightarrow \boxed{f_Y = \frac{dP^{T \circ X}}{d\nu} = (f \circ T^{-1}) \cdot |J_{T^{-1}}|}$$

III :

$$\underline{Th}: X = (X_1, \dots, X_n) : (\Omega, \mathcal{A}, P) \longrightarrow (\prod \Omega_i, \otimes \mathcal{A}_i, \mu = \mu_1 \times \dots \times \mu_n)$$

$$f = \frac{dP^{(X_1, \dots, X_n)}}{d\mu} \Rightarrow \boxed{f_i = \frac{dP^{X_i}}{d\mu_i} = \int_{\prod_{j \neq i} \Omega_j} f \, d(\prod_{j \neq i} \mu_j)}$$

$$(X_i) \text{ indep} \Leftrightarrow P^{(X_1, \dots, X_n)} = P^{X_1} \dots P^{X_n}$$

$$\Leftrightarrow f = f_1 \dots f_n$$

$$\Rightarrow E(X_1 \dots X_n) = E(X_1) \dots E(X_n) ; \text{Var}(\sum X_i) = \sum \text{Var}(X_i).$$

IV :

$$\int_{X^{-1}(A)} Y \, dP = \int_A E(Y|X) \, dP^X ; \int_B Y \, dP = \int_B E(Y|B) \, dP \quad \forall B \in \mathcal{B} \subseteq \mathcal{A}.$$

$$E(a_1 X_1 + a_2 X_2 | X) = a_1 E(X_1 | X) + a_2 E(X_2 | X).$$

$$X, Y \text{ indep.} \Rightarrow E(XY | X=t) = E(X | X=t) \cdot E(Y | X=t).$$

$$\text{Eigend., } E(f_0 X | X=t) = f(t), \quad E(Y(f_0 X) | X=t) = f(t) \cdot E(Y | X=t).$$

V :

$$X, Y \text{ indep.} \Leftrightarrow \forall A_i \in \mathcal{A}_i, P(Y_i \in A_i | X) = \text{cte} = P(Y_i \in A_i).$$

$$\Rightarrow \text{if } Y \text{ v.c.r. } E(Y | X=x) = E(Y).$$

$$f = \frac{dP^{(X,Y)}}{d(\mu^X \times \mu^Y)} \Rightarrow \boxed{f^{Y|X=x}(y) = \frac{f(x,y)}{\underbrace{f_X(x)}_{\text{dist. marg. resp. } X}}}$$

$$\boxed{E(Y | X=x) = \int y f^{Y|X=x}_{(y)} \, dy}$$

VI: FUNCIONES CARACTERÍSTICAS

Definición: Sea P una probabilidad en el espacio de Borel $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$. Se llame función característica de P a

$$\begin{aligned}\varphi_P: \mathbb{R} &\longrightarrow \mathbb{C} \\ t &\longmapsto \varphi_P(t) := \int e^{itx} dP(x) = E[e^{itx}]\end{aligned}$$

Definición: Sea X una v.a.r. definida en $(\Omega, \mathcal{A}, P)$. Se llame función característica de X a la función característica de P^X , ie,

$$\begin{aligned}\varphi_X: \mathbb{R} &\longrightarrow \mathbb{C} \\ t &\longmapsto \varphi_X(t) := \varphi_{P^X}(t) = \int e^{itx} dP^X(x) = \int e^{itX(\omega)} dP(\omega) = E[e^{itX(\omega)}]\end{aligned}$$

de existencia está generalizada por la integrabilidad de $e^{itX(\omega)}$.

Proposición:

1) Si X es una v.a.r. discreta que toma valores $x_1, x_2, \dots$ con probabilidades $p_1, p_2, \dots$; entonces

$$\varphi_X(t) = \sum_{k \geq 1} p_k e^{itx_k}$$

2) Si X es una v.a.r. abs. continua resp. m con función de densidad f , entonces

$$\varphi_X(t) = \int_{-\infty}^{\infty} e^{itx} f(x) dx$$

Proposición: Sean $X_1, \dots, X_n$ v.a.r. independientes. Entonces $\varphi_{\sum X_i}(t) = \prod_i \varphi_{X_i}(t)$.

Proposición: Sea X v.a.r., $a, b \in \mathbb{R}$. Entonces $\varphi_{aX+b}(t) = e^{ibt} \varphi_X(at)$.

Proposición: Si X tiene momento absoluto de orden k finito $\Rightarrow \varphi_X$ admite derivada k -ésima, y es

$$\varphi_X^{(k)}(t) = \int_{\mathbb{R}} (ix)^k e^{itx} dP_X^x$$

luego, en particular, $E[X^k] = \frac{1}{i^k} \varphi_X^{(k)}(0)$.

Teorema: $\varphi_X = \varphi_Y \iff P^X = P^Y$. ($\Leftrightarrow X$ e Y siguen la misma dist. de prob.)

Definición: Sea $X = (X_1, \dots, X_n)$ una v.a. n -dim. Se llama función característica de X a

$$\begin{aligned} \varphi_X: \mathbb{R}^n &\longrightarrow \mathbb{C} \\ u &\longmapsto \varphi_X(u) := \int e^{i\langle u, X \rangle} dP = E\left[e^{i\sum u_j X_j}\right] \end{aligned}$$

Teorema (Caracterización de independencia): Sea $X_1, \dots, X_n$ v.a.r. y consideremos $(X_1, \dots, X_n)$ vector aleatorio.

$$X_1, \dots, X_n \text{ independientes} \iff \varphi_{(X_1, \dots, X_n)} = \varphi_{X_1} \cdots \varphi_{X_n}$$

Proposición: Sea $X \sim N(\mu, \sigma^2)$. Entonces

$$\boxed{\varphi_X(t) = e^{it\mu - \frac{1}{2}t^2\sigma^2}}$$

Proposición: Sea $X \sim G(\alpha, \beta)$. Entonces

$$\varphi_X(t) = \frac{1}{(1 - \beta i t)^\alpha}$$

Proposición: Sea $X \sim b_n(p)$. Entonces

$$\varphi_X(t) = (p e^{it} + 1 - p)^n$$

Corolario: Si $X_1, \dots, X_n$ indep, $X_i \sim b_{n_i}(p) \Rightarrow \sum X_i \sim b_{\sum n_i}(p)$.

Proposición: Sea $X \sim P_\lambda$. Entonces

$$\varphi_X(t) = e^{\lambda(e^{it} - 1)}$$

Corolario: Si $X_1, \dots, X_n$, indep, $X_i \sim P_{\lambda_i} \Rightarrow \sum X_i \sim P_{\sum \lambda_i}$.

Definición: Una v.a. n -dim $X: (\Omega, \mathcal{F}, P) \rightarrow \mathbb{R}^n$ se dice normal si su función característica es

$$\varphi_X(t) = e^{i t^t b - \frac{1}{2} t^t C t}, \quad t \in \mathbb{R}^n$$

donde $b \in \mathbb{R}^n$ y $C = (C_{ij}) \in \text{lin}(\mathbb{R})$ es simétrica y semidefinida positiva (ie, $t^t C t \geq 0 \forall t \in \mathbb{R}^n$).

En esta situación se dice que X tiene distribución normal multivariante de media b y matriz de

covarianzas C , y podemos $X \sim N_n(b, C)$

Proposición: Sea $A \in M_{m \times n}$, $b \in \mathbb{R}^m$ y $X' = (X'_1 \dots X'_n) : (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}^n$ de componentes v.a. independientes, y cada $X'_j \sim N(0, \lambda_j)$ ($j=1 \dots n$). Entonces la v.a. m -dimensional

$$X := AX' + b \sim N_m(b, C), \text{ donde } C = ADA^t, \text{ con } D = \text{diag}(\lambda_1, \dots, \lambda_n).$$

• Es decir, y dadas un vector aleatorio n -dim, cuyos componentes tienen distr. normal (1-variate), podemos construir una variable multidimensional gauss normal multivariante. ¿Y el recíproco? Sí.

Proposición: Sea $X \sim N_n(b, C)$, C matriz simétrica y semidefinita positiva. Entonces existe $A \in M_n$ ortogonal y una v.a. n -dim $X' = (X'_1, \dots, X'_n)$ con $X_j \sim N(0, \lambda_j)$ e independientes tal que $X = AX' + b$, y λ_i son los autovalores de C .

Leads: $X \sim N_n(b, C) \Rightarrow E[X] = b, \text{ Cov}[X] = C.$

• Tipo n° 6 bien puesto bien de nombre auto.

Proposición: X_1, X_2 normales e indep. $\Rightarrow (X_1, X_2)$ normal ($X = AX' + b$ con auto)

Proposición: Sea $X \sim N_n(b, C)$, $X' = (X'_1 \dots X'_n)$, $X'_j \sim N(0, \lambda_j)$, C simétrica y semidefinita positiva.

Si $C^{-1} \Rightarrow X$ es abs. continua respecto m_n y la función de densidad de la normal multivariante es

$$f(x) = \frac{1}{\sqrt{(2\pi)^n |C|}} e^{-\frac{1}{2}(x-b)^t C^{-1}(x-b)} \quad x \in \mathbb{R}^n.$$

Proposición: X tiene distr. normal (multivariante) $\iff u^t X$ tiene distr. normal (unidim) $\forall u \in \mathbb{R}^n$.

Proposición: Sea X una v.a. n -dim normal, $X = (X_1 \dots X_n)$.

$$X_1 \dots X_n \text{ independientes} \iff X_1 \dots X_n \text{ incorreladas.}$$

VII : MUESTRAS

Definición: Se llama muestra a una colección de variables aleatorias iid. En el caso finito, se llama tamaño de la muestra al número de v.a. considerados. Por nosotros serán v.a. reales.

Definición: Sea $X_1, \dots, X_n$ una muestra de tamaño n . Se llama función de distribución empírica o muestral a

$$F_n: \mathbb{R} \times \Omega \longrightarrow \mathbb{R}$$

$$(x, \omega) \longmapsto F_n(x, \omega) := \frac{1}{n} \sum_{j=1}^n \mathbb{I}_{(-\infty, x]}(X_j(\omega))$$

*Nota que dicha suma (sin $\frac{1}{n}$) es el número de variables de la muestra tal que $X_j(\omega) \leq x$.

Proposición:

- 1) Dado $x \in \mathbb{R}$ fijo, $F_n(x, \cdot): \Omega \rightarrow \mathbb{R}$ es una v.a. de distribución $b_n(F(x))$.
- 2) Dado $\omega \in \Omega$ fijo, $F_n(\cdot, \omega): \mathbb{R} \rightarrow \mathbb{R}$ es la función de distribución de una v.a. discreta.

Definición: Sea $X_1, \dots, X_n$ una muestra de tamaño n . Llamaremos

- i) media muestral a la v.a. $\bar{X}(\omega) := \frac{1}{n} \sum_{i=1}^n X_i(\omega)$.
- ii) momento muestral de orden k a la v.a. $a_k(\omega) := \frac{1}{n} \sum_{i=1}^n X_i^k(\omega)$.
- iii) momento muestral absoluto de orden k a la v.a. $A_k(\omega) := \frac{1}{n} \sum_{i=1}^n |X_i^k(\omega)|$.
- iv) momento central muestral de orden k a la v.a. $b_k(\omega) := \frac{1}{n} \sum_{i=1}^n (X_i(\omega) - \bar{X}(\omega))^k$.
- v) momento central muestral absoluto de orden k a la v.a. $B_k(\omega) := \frac{1}{n} \sum_{i=1}^n |X_i(\omega) - \bar{X}(\omega)|^k$.
- vi) varianza muestral (o cuasi-varianza muestral) a la v.a. $S^2(\omega) := \frac{1}{n-1} \sum (X_i(\omega) - \bar{X}(\omega))^2$.

Proposición: Sea $X_1, \dots, X_n$ una muestra de tamaño n .

- 1) X_1 tiene media finita $\Rightarrow E[\bar{X}] = E[X_1]$
- 2) X_1 tiene varianza finita $\Rightarrow \text{Var}[\bar{X}] = \frac{1}{n} \text{Var}[X_1]$
- 3) X_1 tiene momentos de orden k finito $\Rightarrow E[a_k] = E[X_1^k]$
- 4) X_1 tiene momentos finitos de orden $k \Rightarrow E[S^2] = \text{Var}[X_1]$.

• Por 4) se le llama a S^2 "varianza muestral" y se usa s^2 .

Definición: Sea $X \sim N(0,1)$ y $Y \sim \chi^2(n) = \chi^2(\frac{n}{2}, 2)$ v.a.r. independientes. Entonces la distribución t de Student de n grados de libertad a la que se refiere la v.a.

$$\sqrt{n} \frac{X}{\sqrt{Y}} \sim t(n).$$

Definición: Sea $X \sim \chi^2(m)$, $Y \sim \chi^2(n)$ dos v.a.r. independientes. Se llama distribución F de Snedecor (o F de Fisher), con (m, n) grados de libertad a la que se refiere la v.a.

$$\frac{X/m}{Y/n} \sim F(m, n).$$

Proposición:

- 1) $X \sim N(\mu, \sigma^2)$, $a, b \in \mathbb{R} \Rightarrow aX + b \sim N(a\mu + b, a^2\sigma^2)$
- 2) $X_1, \dots, X_n$ v.a.r. indep., $X_i \sim N(\mu_i, \sigma_i^2) \Rightarrow \sum X_i \sim N(\sum \mu_i, \sum \sigma_i^2)$.
- 3) " $X_i \sim \gamma(\alpha_i, \beta) \Rightarrow \sum X_i \sim \gamma(\sum \alpha_i, \beta)$
- 4) " $X_i \sim \chi^2(u_i) \Rightarrow \sum X_i \sim \chi^2(\sum u_i)$

Teorema: Sean $X_1, \dots, X_n$ una muestra de tamaño n de distribución $N(\mu, \sigma^2)$, iid

$$1) \bar{X} \sim N(\mu, \frac{\sigma^2}{n})$$

$$2) \bar{X} \text{ y } (X_1 - \bar{X}, \dots, X_n - \bar{X}) \text{ son v.a. independientes}$$

$$3) (\text{Teorema de Fisher}) : \bar{X} \text{ y } S^2 \text{ son independientes.}$$

$$4) (n-1) \frac{1}{\sigma^2} S^2 \sim \chi^2(n-1)$$

$$5) \sqrt{n} \frac{\bar{X} - \mu}{\sqrt{S^2}} \sim t(n-1).$$

• 5) dice que se distribuye la normal cuando se usa la variancia muestral y la media muestral. Se proba que $t(n) \rightarrow N(0,1)$.

Proposición: Sean $X_1, \dots, X_m; Y_1, \dots, Y_n$ dos muestras: $X_i \sim N(\mu_X, \sigma_X^2)$ y $Y_i \sim N(\mu_Y, \sigma_Y^2)$.

Consideren las variancias muestrales de ambas $S_X^2 = \frac{1}{m-1} \sum_{i=1}^m (X_i - \bar{X})^2$ y $S_Y^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2$.

$$1) \frac{S_X^2 / \sigma_X^2}{S_Y^2 / \sigma_Y^2} \sim F(m-1, n-1)$$

$$2) \text{ Si } \sigma_X^2 = \sigma_Y^2, \quad \frac{(\bar{X} - \bar{Y}) - (\mu_X - \mu_Y)}{\sqrt{S^2} \sqrt{\frac{1}{m} + \frac{1}{n}}} \sim t(m+n-2), \text{ donde}$$

$$S^2 = \frac{1}{m+n-2} \left[\sum_{i=1}^m (X_i - \bar{X})^2 + \sum_{i=1}^n (Y_i - \bar{Y})^2 \right] \text{ es la variancia muestral combinada}$$

VIII : SUCESSIONES DE VVAA

Definición: Sea $(X_n) : (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}$ una sucesión de v.a.r. Diremos que

i) (X_n) converge c.s. a X , $(X_n) \xrightarrow{\text{c.s.}} X$, si $\exists A \in \mathcal{A}, P(A) = 1 : X_n(\omega) \xrightarrow{\text{en } \mathbb{R}} X(\omega)$

$\forall \omega \in A$, i.e. si $P\{\omega \in \Omega : X_n(\omega) \nrightarrow 0\} = 0$.

ii) (X_n) converge en probabilidad a X , $(X_n) \xrightarrow{P} X$, si $P(\{\omega \in \Omega : |X_n(\omega) - X(\omega)| > \varepsilon\}) \rightarrow 0$,

$\forall \varepsilon > 0$, o bien si $P(|X_n - X| \leq \varepsilon) \rightarrow 1 \quad \forall \varepsilon$.

iii) $(X_n) \in \mathcal{L}^1$ converge en $\mathcal{L}^1$ o en media a $X \in \mathcal{L}^1$, $(X_n) \xrightarrow{\mathcal{L}^1} X$ si $E[|X_n - X|] \rightarrow 0$.

iv) $(X_n) \in \mathcal{L}^p$ converge en $\mathcal{L}^p$ o en media p a $X \in \mathcal{L}^p$, $(X_n) \xrightarrow{\mathcal{L}^p} X$ si $E[|X_n - X|^p] \rightarrow 0$.

v) (X_n) converge en distribución a X , $(X_n) \xrightarrow{d} X$ si $F_{X_n}(x) \rightarrow F_X(x) \quad \forall x$ pto de cont. de F_X .

Proposición: En todas las convergencias salvo en distribución el límite, si existe, es único P-c.s.

La convergencia c.s. es la versión probabilística de la convergencia puntual, y la convergencia en probabilidad de la uniforme.

Nota que estas nuevas son más débiles, pero permiten que no se exija en un conjunto de prob. nula.

$(X_n) \xrightarrow{\mathcal{L}^1} X \Rightarrow (E[X_n]) \rightarrow E[X]$.

Definición: (X_n) se dice de Cauchy c.s. si $\exists A \in \mathcal{A}, P(A) = 1 : |X_n(\omega) - X_m(\omega)| \xrightarrow{n, m \rightarrow \infty} 0$, o bien,

si $P\{\omega : |X_n(\omega) - X_m(\omega)| \nrightarrow 0\} = 0$.

Proposición: (X_n) converge c.s. $\iff (X_n)$ de Cauchy c.s.

Definición: Sea $(A_n)_{n \in \mathbb{N}}$ una sucesión de conjuntos. Se llaman

i) límite superior a $\overline{\lim} A_n := \bigcap_{n=1}^{\infty} \bigcup_{m=n}^{\infty} A_n = \{ \omega \in \Omega \text{ que pertenecen a infinitas } A_n \}$.

ii) límite inferior a $\underline{\lim} A_n := \bigcup_{n=1}^{\infty} \bigcap_{m=n}^{\infty} A_n = \{ \omega \in \Omega \text{ que pertenecen a todos los } A_n \text{ salvo a lo más finitos} \}$.

Teorema: Sea (X_n) una suc. de v.c.r. Son equivalentes:

$$1) (X_n) \xrightarrow{\text{c.s.}} X$$

$$2) P\left(\bigcup_{m=n}^{\infty} \{ |X_m - X| > \varepsilon \} \right) \xrightarrow{n \rightarrow \infty} 0 \quad \forall \varepsilon$$

$$3) P\left(\bigcap_{k=1}^{\infty} \underline{\lim} \{ |X_n - X| \leq \frac{1}{k} \} \right) = 1$$

Proposición: (X_n) Cauchy c.s. $\iff P\left(\bigcup_{n=1}^{\infty} \{ |X_{n+m} - X_n| > \varepsilon \} \right) \xrightarrow{n \rightarrow \infty} 0$

Corolario: $(X_n) \xrightarrow{\text{c.s.}} X \iff \left(\sup_{m \geq n} |X_m - X| \right) \xrightarrow{P} 0$

Corolario: $\sum_{n=1}^{\infty} P(\{ |X_n - X| > \varepsilon \}) < \infty \quad \forall \varepsilon \implies (X_n) \xrightarrow{\text{c.s.}} X$. En este caso

se dice que (X_n) converge completamente a X .

Teorema (de representación de Skorokhod): Sea $(X_n) \xrightarrow{d} X$ def. en $(\Omega, \mathcal{A}, P)$. Entonces existe

$(\Omega', \mathcal{A}', P')$ y $(Y_n), Y$:

$$1) P^{X_n} = P^{Y_n}, \quad P^X = P^Y$$

$$2) (Y_n) \xrightarrow{\text{c.s.}} Y$$

• Definimos $\mathcal{C}_0 := \{f: \mathbb{R} \rightarrow \mathbb{R} \text{ continuas y acotadas}\}$.

Proposición: $(X_n) \xrightarrow{d} X \iff E[f(X_n)] \rightarrow E[f(X)] \quad \forall f \in \mathcal{C}_0$.

Levelans: $E[f(X_n)] \rightarrow E[f(X)] \quad \forall f \in C^k, k \in \mathbb{N} \implies (X_n) \xrightarrow{d} X$.


Teorema (de continuidad de Lévy): Sea (X_n) se. de v.a.s. con funciones características φ_{X_n} .

$$1) (X_n) \xrightarrow{d} X \iff (\varphi_{X_n}(t)) \rightarrow \varphi_X(t) \quad \forall t.$$

2) Si $\lim_{n \rightarrow \infty} \varphi_{X_n}(t) =: \varphi(t)$ existe $\forall t \in \mathbb{R}$ y es cont. en 0, existe X v.a. tal que

$(X_n) \xrightarrow{d} X$ y tiene como func. característica φ .

RELACIONES DE CONVERGENCIA



Proposición: $(X_n) \xrightarrow{c.s.} X \Rightarrow (X_n) \xrightarrow{P} X$.

Definición: (X_n) se dice de Cauchy en probabilidad si $\forall \varepsilon > 0 \quad P(\{ |X_n - X_m| > \varepsilon \}) \xrightarrow{n, m \rightarrow \infty} 0$.

Proposición: $(X_n) \xrightarrow{P} X \iff (X_n) \text{ de Cauchy en probabilidad}$.

Proposición: $(X_n) \xrightarrow{L^1} X \Rightarrow (X_n) \xrightarrow{P} X \quad ((X_n), X \in L^1)$.

Teorema (Udozgerov): $(X_n) \xrightarrow{P} X \Rightarrow (X_n) \xrightarrow{d} X$.

• CONTRA EJEMPLOS:

$$-(X_n) \xrightarrow{d} X \not\Rightarrow (X_n) \xrightarrow{P} X \quad : X_n = I_{[0, \frac{1}{2} + \frac{1}{n}]} \quad , n \geq 2.$$

$$-(X_n) \xrightarrow{P} X \not\Rightarrow (X_n) \xrightarrow{c.s.} X \quad : X_{n,k} := n \cdot I_{[\frac{k-1}{n}, \frac{k}{n})} \quad , \begin{matrix} k=1 \dots n \\ n=2, 3, \dots \end{matrix}$$

$$-(X_n) \xrightarrow{P} X \not\Rightarrow (X_n) \xrightarrow{L^1} X \quad : X_n := n \cdot I_{[0, \frac{1}{n})}$$

$$-(X_n) \xrightarrow{L^1} X \not\Rightarrow (X_n) \xrightarrow{L^2} X \quad : X_n := \sqrt{n} \cdot I_{[0, \frac{1}{n})}$$

Lema: $(X_n) \xrightarrow{d} c \in \mathbb{R} \Rightarrow (X_n) \xrightarrow{P} c \in \mathbb{R}$.

Proposición: $(X_n) \uparrow_P X \Rightarrow (X_n) \xrightarrow{c.s.} X$

Proposición: $(X_n) \xrightarrow{P} X, |X_n| \leq M \Rightarrow (X_n) \xrightarrow{L^1} X$.

Lema (de absoluta continuidad): Sea $X \in L^1$.

$$\forall \varepsilon > 0 \quad \exists \delta > 0 : A \in \mathcal{A}, P(A) < \delta \Rightarrow E[|X| I_A] < \varepsilon.$$

Lema: Sea $X \in L^1$.

$$\forall \varepsilon > 0 \quad \exists K > 0 : E[|X| I_{\{|X| > K\}}] < \varepsilon.$$

Definición: Una familia de v.a. $\mathcal{G}$ se dice uniformemente integrable si

$$\forall \varepsilon > 0 \quad \exists K > 0 : E[|X| I_{\{|X| > K\}}] < \varepsilon \quad \forall X \in \mathcal{G}.$$

Lema: Toda familia $\mathcal{G}$ u.i. es acotada en L^1 (ie, todos son integrables y dichos integrales están acotados)

Ejemplo: $\mathcal{G}$ acotada en $L^1 \not\Rightarrow \mathcal{G}$ u.i. : $X_n = n I_{[0, \frac{1}{n}]}$.

Proposición (Criterios Suficientes de u.i.):

1) $\mathcal{G}$ acotada en $L^p, p > 1 \Rightarrow \mathcal{G}$ u.i.

2) $\mathcal{G}$ dominados por una v.a. integrable $\geq 0 \Rightarrow \mathcal{G}$ u.i.

Teorema: Sea $(X_n), X \in L^1$.

$$(X_n) \xrightarrow{L^1} X \iff \begin{cases} 1) (X_n) \xrightarrow{P} X \\ 2) \mathcal{G} = \{X_n\} \text{ es u.i.} \end{cases}$$

CONVERGENCIA BAJO TRANSFORMACIONES

Teorema: Sean $(X_n), (Y_n), X, Y$ v.a. Si $(X_n) \rightarrow X, (Y_n) \rightarrow Y$ casi seguro (en probabilidad) (en $L^p, p > 1$) $\Rightarrow (X_n + Y_n) \rightarrow X + Y$ casi seguro (en probabilidad) (en L^p).

Proposición (Slutsky): $(X_n) \xrightarrow{d} X, (Y_n) \xrightarrow{d} c \in \mathbb{R} \Rightarrow (X_n + Y_n) \xrightarrow{d} X + c$

Teorema: Sean $(X_n), (Y_n), X, Y$ v.a. Si $(X_n) \rightarrow X, (Y_n) \rightarrow Y$ casi seguro (en probabilidad) (en L^p y en L^q , resp. p. q exp conj.) $\Rightarrow (X_n, Y_n) \rightarrow X, Y$ casi seguro (en probabilidad) (en L^1).

Proposición (Slutsky): $(X_n) \xrightarrow{d} X, (Y_n) \xrightarrow{d} c \in \mathbb{R} \Rightarrow (X_n, Y_n) \xrightarrow{d} c \cdot X$.

Proposición: Sea $g: \mathbb{R} \rightarrow \mathbb{R}$ continua, y (X_n) una sec. de v.a. Si $(X_n) \rightarrow X$ casi seguro (en probabilidad) (en distribución) $\Rightarrow (g(X_n)) \rightarrow g(X)$ casi seguro (en probabilidad) (en distribución).

CONVERGENCIA DE VECTORES ALEATORIOS

• Ahora los sucesos serán $(X_n) = ((X_n^1, \dots, X_n^k))$, y cambia el valor adalt por la norm euclida.

Definición: Sea (X_n) una sucesión de vectores aleatorios k -dimensionales, def en $(\Omega, \mathcal{A}, P)$.

- i) $(X_n) \xrightarrow{c.s.} X$ si $\exists A \in \mathcal{A}, P(A) = 1 : \forall \omega \in A \quad X_n(\omega) \xrightarrow{\text{en } \mathbb{R}^k} X(\omega)$
- ii) $(X_n) \xrightarrow{P} X$ si $P(\{\|X_n(\omega) - X(\omega)\|_2 > \epsilon\}) \xrightarrow{n \rightarrow \infty} 0 \quad \forall \epsilon$.
- iii) $(X_n) \xrightarrow{L^2} X$ si $E[\|X_n - X\|_2^2] \rightarrow 0$.
- iv) $(X_n) \xrightarrow{L^1} X$ si $E[\|X_n - X\|_1] \rightarrow 0$.
- v) $(X_n) \xrightarrow{d} X$ si $E[f(X_n)] \rightarrow E[f(X)] \quad \forall f: \mathbb{R}^k \rightarrow \mathbb{R}$ cont. y acotada.

Proposición: Para la convergencia c.s., en probabilidad, en L^2 y L^1 se tiene:

$$(X_n) \rightarrow X \iff (X_n^i) \rightarrow X^i, \quad i=1, \dots, k,$$

y para la convergencia en distribución se cumple:

$$(X_n) \xrightarrow{d} X \iff (X_n^i) \xrightarrow{d} X^i, \quad i=1, \dots, k$$

Levy (Tchebycheff): Si (X_n) suc. de v.a. independientes e ident. distr. con $\mu = E[X_i]$,

$\sigma^2 = \text{Var}[X_i]$, entonces $\frac{S_n - n\mu}{n} \xrightarrow{P} 0$, o bien

$$\underline{\underline{\frac{S_n}{n} \xrightarrow{P} \mu}} \quad (\text{que es un v.a. degenerada}).$$

es decir, $\frac{1}{n} S_n = \frac{1}{n} \sum X_i = \bar{X} \xrightarrow{P} \mu$.

Levy: (X_n) suc. de v.a. independientes, $X_i \sim b_1(p)$, $\frac{S_n}{n} \equiv$ frecuencia relativa en la que ocurre el suceso los n primeros veces, converge a $p \equiv$ prob. en la que ocurre el suceso.

Levy: Dado $\varepsilon > 0$ y $0 < \delta \leq 1$, eligiendo $n > \frac{p(1-p)}{\varepsilon^2 \delta}$ (o $n > \frac{1}{4\varepsilon^2 \delta}$, si p

es desconocido) se tiene que $P\left(\left|\frac{S_n}{n} - p\right| \leq \varepsilon\right) \geq 1 - \delta$.

Teorema (Khintchine): Sea (X_n) me suc. de v.a. i.i.d. de momento absoluto finito y $\mu = E[X_i] \forall i$.

Entonces $\frac{S_n - n\mu}{n} \xrightarrow{P} 0$, o bien

$$\underline{\underline{\frac{S_n}{n} \xrightarrow{P} \mu}}$$

Definición: Una sucesión de v.a. (X_n) se dice que satisface la Ley Fuerte de los Grandes Números respecto a la sucesión de cts normalizadoras (B_n) si existe una sucesión de cts (A_n) tal que

$$\frac{S_n - A_n}{B_n} \xrightarrow{\text{c.s.}} 0.$$

Théorème : Soit (X_n) s.v. de v.a. indep. pour $E[X_i] = 0$ et $0 < \sigma_i^2 = \text{Var}[X_i] < \infty \forall i$.

Si $\sum_{i=1}^{\infty} \sigma_i^2 < \infty \Rightarrow \sum_{i=1}^{\infty} X_i$ converge c.s.

Lemme (Cesàro) ^{Kronecker} : Soit $(X_n) \xrightarrow{\text{c.s.}} x$, $(b_n) \xrightarrow{\text{a.M.}} \infty$. Alors $\left(\frac{1}{b_n} \sum_{i=1}^n (b_i - b_{i-1}) X_i \right) \rightarrow x$. En

particulier, car $b_n = n$, $\frac{1}{n} \sum_{i=1}^n X_i \equiv \text{moyenne} \rightarrow x$. Alors, $\left(\frac{1}{b_n} \sum_{i=1}^n b_i X_i \right) \rightarrow 0$.

Théorème : Soit (X_n) une s.v. de v.a. indep. avec $\mu_i = E[X_i]$ et $0 < \sigma_i^2 = \text{Var}[X_i] < \infty \forall n$.

Soit $(B_n) \rightarrow \infty$ et $\lambda > 0$. Si $\sum_{n=1}^{\infty} \frac{\sigma_n^2}{B_n^2} < \infty$, alors

$$\frac{S_n - \sum_{i=1}^n \mu_i}{B_n} \xrightarrow{\text{c.s.}} 0.$$

Lemme ^{*} : (X_n) indep. $\mu_i = E[X_i]$ et $\sigma_i^2 = \text{Var}[X_i] < \infty$. Si $\sum \frac{\sigma_n^2}{n^2} < \infty$, alors

$$\frac{S_n - \sum \mu_i}{n} \xrightarrow{\text{c.s.}} 0$$

Lemme : (X_n) indep., $\mu_i = E[X_i]$ et $\sigma_i^2 = \text{Var}[X_i] \leq M$, $M \geq 0$, alors

$$\frac{S_n - \sum \mu_i}{n} \xrightarrow{\text{c.s.}} 0$$

Lemme : (X_n) iid, $\mu = E[X_i]$, $\sigma^2 = \text{Var}[X_i] < \infty \forall i$, alors $\frac{S_n - n\mu}{n} \xrightarrow{\text{c.s.}} 0$, ou bien,

$$\underline{\underline{\frac{S_n}{n} \xrightarrow{\text{c.s.}} \mu}}$$

Teorema (Kolmogorov): (X_n) iid, $E[|X_i|] < \infty$ y $\mu = E[X_i]$. Entonces $\frac{S_n - n\mu}{n} \xrightarrow{a.s.} 0$, es decir,

$$\frac{S_n}{n} \xrightarrow{a.s.} \mu.$$

LA CENTRAL DEL LIMITE

Teorema: Sea (X_n) iid de distribución común $b_1(p)$, $0 < p < 1$, y sea $S_n = \sum_{i=1}^n X_i$.

1) (Bernoulli): $\frac{S_n}{n} \xrightarrow{d} p$

2) (De Moivre-Laplace): $\frac{S_n - E[S_n]}{\sqrt{\text{Var}[S_n]}} \xrightarrow{d} Z$, $Z \sim N(0, 1)$.

Teorema (Poisson): Para cada $n \in \mathbb{N}$, sea $X_{n1}, \dots, X_{nn}$ v.a. iid con distribución $b_1(p_n)$, $0 < p_n < 1$, y sea $S_n = \sum_{i=1}^n X_{ni}$. Si $np_n \rightarrow \lambda \in (0, \infty)$, entonces

$$S_n \xrightarrow{d} Y, \quad Y \sim P(\lambda).$$

• Esto dice que $b_1(p_n) \rightarrow P_\lambda$ cuando $n \rightarrow \infty$, pues $S_n \sim b_n(p)$.

Teorema (Lindenberg-Lévy): Sea (X_n) sec. de v.a. iid, $\mu = E[X_i]$ y $\sigma^2 = \text{Var}[X_i] < \infty \quad \forall i$. Si $S_n = \sum_{i=1}^n X_i$, entonces

$$\frac{S_n - n\mu}{\sqrt{n\sigma^2}} \xrightarrow{d} Z, \quad Z \sim N(0, 1).$$

$$\parallel$$

$$\frac{S_n - E[S_n]}{\sqrt{\text{Var}[S_n]}}$$