

# Capítulo 1

## Sucesiones de Variables Aleatorias

### 1.1. Introducción

La introducción de los conceptos de medida e integral nos va a permitir considerar nuevos modos de convergencia para sucesiones de funciones. Vamos a comenzar por recordar dos conceptos clásicos de convergencia.

**Definición 1.1** Sea  $X_n$ ,  $n \geq 1$  una sucesión de funciones medibles a valores reales definidas sobre el espacio de medida  $(\Omega, \mathcal{F}, \mu)$  y  $X$  una función real y medible, definida sobre el mismo espacio. Decimos que la sucesión  $(X_n)$  converge (puntualmente) a  $X$  si para todo  $\omega \in \Omega$  se tiene que

$$\lim_{n \rightarrow \infty} X_n(\omega) = X(\omega),$$

es decir, dados  $\omega \in \Omega$  y  $\varepsilon > 0$  existe  $N = N(\omega, \varepsilon) \in \mathbb{N}$  tal que

$$n \geq N \Rightarrow |X_n(\omega) - X(\omega)| < \varepsilon$$

Usamos la notación

$$X_n \rightarrow X$$

para denotar la convergencia puntual.

**Definición 1.2** Sean  $X_n$ ,  $n \geq 1$  y  $X$  como en la definición anterior. Decimos que la sucesión  $(X_n)$  converge uniformemente a  $X$  si dado  $\varepsilon > 0$  existe  $N = N(\varepsilon) \in \mathbb{N}$  tal que, para cualquier punto  $\omega$  en  $\Omega$  se tiene que

$$n \geq N \Rightarrow |X_n(\omega) - X(\omega)| < \varepsilon$$

Usamos la notación

$$X_n \xrightarrow{U} X$$

para denotar la convergencia uniforme.

#### Observación 1.1

- La diferencia entre las dos definiciones radica en que en el primer caso  $N$  depende del punto  $\omega$  en el cual estamos viendo la convergencia, mientras que en el segundo caso el mismo  $N$  sirve para todos los puntos del espacio.
- La segunda definición dice que si consideramos una banda de ancho  $2\varepsilon$  alrededor de la función  $X$ , existe un  $N$  que depende únicamente de  $\varepsilon$  tal que, si  $n \geq N$  la función  $X_n$  está dentro de esta banda.
- Es claro que convergencia uniforme implica convergencia puntual pero el recíproco es falso.

## 1.2. Convergencia Casi Segura

**Definición 1.3** Sean  $X_n$ ,  $n \geq 1$  y  $X$  como en la definición 1.1. Decimos que la sucesión  $(X_n)$  converge casi seguramente a  $X$  si existe un conjunto nulo  $N \in \mathcal{F}$  tal que, para cualquier punto  $\omega \notin N$  se tiene que

$$X_n(\omega) \rightarrow X(\omega).$$

Usamos las notaciones

$$X_n \xrightarrow{c.s.} X \quad \text{o} \quad X_n \rightarrow X, \quad c.s.$$

para denotar la convergencia casi segura. Si  $(\Omega, \mathcal{F}, \mu)$  es un espacio de probabilidad este tipo de convergencia se conoce como *convergencia con probabilidad 1* y se denota

$$X_n \xrightarrow{c.p.1} X \quad \text{o} \quad X_n \rightarrow X, \quad c.p.1$$

Es obvio que convergencia puntual implica convergencia c.s. y el siguiente ejemplo muestra que el recíproco no es cierto.

### Ejemplo 1.1

Sea  $(\Omega, \mathcal{F}, \mu)$  el espacio de Lebesgue  $([0, 1], \mathcal{B}, \lambda)$  y  $X_n(\omega) = \omega^n$ ,  $X(\omega) = 0$  para  $\omega \in [0, 1]$ . Entonces

$$X_n(\omega) \rightarrow 0 \quad \text{para } \omega \in [0, 1),$$

es decir, la sucesión  $X_n$  converge a  $X$  salvo en el punto 1, de modo que el conjunto donde no hay convergencia es un conjunto nulo que no es vacío.

**Proposición 1.1** Si  $(\Omega, \mathcal{F}, \mu)$  es un espacio completo,  $X_n \xrightarrow{c.s.} X$  y las funciones  $X_n$  son medibles, entonces  $X$  también es medible.

**Demostración.** Sabemos que existe un conjunto nulo (y por lo tanto medible)  $N$  tal que  $X_n$  converge a  $X$  fuera de  $N$ , es decir, si  $\omega \notin N$

$$\liminf_{n \rightarrow \infty} X_n(\omega) = \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega).$$

Para  $c \in \mathbb{R}$  los conjuntos

$$A_1 = \{\omega : X(\omega) > c\}, \quad A_2 = \{\omega : \liminf X_n(\omega) > c\}$$

no necesariamente coinciden, pero cualquier punto que esté en uno y no esté en otro debe estar en  $N$ . Además, sabemos que  $A_2$  es medible porque  $\liminf X_n$  es medible. Sea

$$B_1 = A_1 - A_2, \quad B_2 = A_2 - A_1.$$

Ambos conjuntos son subconjuntos de  $N$  y como el espacio es completo, son conjuntos medible. Finalmente observamos que

$$A_1 = B_1 \cup (A_2 \cap B_2^c)$$

de modo que  $F_1$  es medible. ■

**Definición 1.4** Sea  $X_n$ ,  $n \geq 1$  como en la definición 1.1. Decimos que la sucesión  $(X_n)$  es de Cauchy casi seguramente si existe un conjunto nulo  $N \in \mathcal{F}$  tal que, para cualquier punto  $\omega \notin N$  la sucesión  $X_n(\omega)$  es de Cauchy.

**Proposición 1.2** Una sucesión de funciones medibles  $(X_n)$  converge c.s. si y sólo si es de Cauchy c.s.

La demostración queda como ejercicio.

### 1.3. Convergencia en Medida

**Definición 1.5** Sean  $X_n$ ,  $n \geq 1$  y  $X$  como en la definición 1.1. Decimos que la sucesión  $(X_n)$  converge en medida a  $X$  si para cualquier  $\varepsilon > 0$  se tiene que

$$\lim_{n \rightarrow \infty} \mu(\{\omega \in \Omega : |X_n(\omega) - X(\omega)| > \varepsilon\}) = 0.$$

Usamos las notaciones

$$X_n \xrightarrow{\mu} X \quad \text{o} \quad X_n \rightarrow X, \text{ en medida}$$

para denotar la convergencia en medida. Si  $(\Omega, \mathcal{F}, \mu)$  es un espacio de probabilidad este tipo de convergencia se conoce como *convergencia en probabilidad* y se denota

$$X_n \xrightarrow{P} X \quad \text{o} \quad X_n \rightarrow X, \text{ en probabilidad.}$$

Ese tipo de convergencia es más débil que la convergencia casi segura, como lo muestran la siguiente proposición y el ejemplo que le sigue.

**Proposición 1.3** Sean  $X_n$ ,  $n \geq 1$  y  $X$  como en la definición 1.1 y supongamos que  $\mu(\Omega) < \infty$ . Si  $X_n$  converge a  $X$  c.s. entonces también converge en medida.

**Demostración.** Si  $X_n \rightarrow X$  c.s. entonces existe  $\varepsilon > 0$

$$\begin{aligned} 0 &= \mu(\{|X_n - X| > \varepsilon\} \text{ para infinitos } n) \\ &= \mu(\limsup\{|X_n - X| > \varepsilon\}) \\ &= \lim_{n \rightarrow \infty} \mu(\cup_{k \geq n} \{|X_k - X| > \varepsilon\}) \\ &\geq \lim_{n \rightarrow \infty} \mu(\{|X_n - X| > \varepsilon\}). \end{aligned}$$

■

Para ver que el recíproco no es cierto tenemos el siguiente ejemplo.

**Ejemplo 1.2**

Sea  $(\Omega, \mathcal{F}, \mu) = ([0, 1], \mathcal{B}, \lambda)$  el espacio de Lebesgue y definimos la siguiente sucesión de variables aleatorias:

$$\begin{aligned} X_1(\omega) &= \mathbf{1}_{[0,1]}(\omega), \\ X_2(\omega) &= \mathbf{1}_{[0,1/2]}(\omega), & X_3(\omega) &= \mathbf{1}_{[1/2,1]}(\omega) \\ X_4(\omega) &= \mathbf{1}_{[0,1/3]}(\omega), & X_5(\omega) &= \mathbf{1}_{[1/3,2/3]}(\omega), & X_6(\omega) &= \mathbf{1}_{[2/3,1]}(\omega), \\ &\vdots & & & & \end{aligned}$$

Observamos que como las variables  $X_n$  son funciones indicadoras de intervalos, sólo son distintas de 0 en esos intervalos, cuya longitud tiende a 0 cuando  $n \rightarrow \infty$ . Esto muestra que  $X_n \rightarrow 0$  en probabilidad. En cambio, para cualquier  $\omega \in [0, 1]$  tenemos que  $X_n(\omega) = 1$  para infinitos valores de  $n$ , y  $X_n(\omega) = 0$  para el resto, que también son infinitos. Por lo tanto la sucesión  $X_n$  no converge puntualmente en ningún punto.

**Ejemplo 1.3**

Para ver que  $\mu(\Omega) < \infty$  es una condición necesaria en el teorema anterior consideramos el siguiente ejemplo: Sea  $X_n = \mathbf{1}_{(-n,n)^c}$ ,  $X = 0$ , entonces observamos que  $X_n(\omega) \rightarrow X(\omega)$  para todo  $\omega$  pero para cualquier  $n \in \mathbb{N}$  y cualquier  $\varepsilon > 0$ ,

$$\mu(\{\omega : |X_n(\omega) - X(\omega)| > \varepsilon\}) = \infty$$

y por lo tanto no hay convergencia en medida.

### 1.3.1. Aplicaciones Estadísticas

Supongamos que tenemos una familia de modelos  $(\Omega, \mathcal{F}, P_\theta), \theta \in \Theta$ , y observamos una muestra aleatoria simple  $X_1, \dots, X_n$ . Con base en estas observaciones queremos estimar el valor del parámetro  $\theta$ , es decir, deseamos seleccionar el modelo correcto.

En esta situación lo usual es usar un *estadístico*  $\hat{\theta}_n = \hat{\theta}(X_1, \dots, X_n)$  para estimar el valor de  $\theta$ . Este estadístico es una variable aleatoria definida sobre el mismo espacio de probabilidad. Decimos que el estimador es *débilmente consistente* si para todo  $\theta \in \Theta$ ,

$$P_\theta(|\hat{\theta}_n - \theta| > \varepsilon) \rightarrow 0, \quad n \rightarrow \infty,$$

es decir, si  $\hat{\theta}_n$  converge en probabilidad al verdadero valor de  $\theta$ . El estimador es *(fuertemente) consistente* si esta convergencia se da con probabilidad 1.

### 1.3.2. Consecuencias de la Convergencia en Medida

Aún cuando hemos visto que convergencia en medida es más débil que convergencia c.s., el siguiente teorema, debido a Riesz, muestra que si tenemos convergencia en medida, siempre hay una subsucesión que converge c.s. al mismo límite.

**Teorema 1.1 (Riesz)** *Si la sucesión  $X_n$  converge en medida a  $X$  en  $\Omega$ , existe una subsucesión  $(X_{n_k})$  que converge c.s. a  $X$ .*

**Demostración.** Como la sucesión de funciones converge en medida podemos hallar  $n_1 \in \mathbb{N}$  tal que

$$\mu(\{\omega \in \Omega : |X_{n_1}(\omega) - X(\omega)| \geq 2^{-1}\}) < 2^{-1}.$$

Para cada  $k > 1$  hallamos  $n_k > n_{k-1}$  tal que

$$\mu(\{\omega \in \Omega : |X_{n_k}(\omega) - X(\omega)| \geq 2^{-k}\}) < 2^{-k}.$$

Veamos que la subsucesión  $(X_{n_k})$  converge c.s. a  $X$ . Sea

$$S_k = \bigcup_{i \geq k} \{\omega \in \Omega : |X_{n_i}(\omega) - X(\omega)| \geq 2^{-i}\}.$$

Observamos que  $S_i$  es una sucesión decreciente de conjuntos. Sea

$$S = \bigcap_{k \geq 1} S_k.$$

Por sub-aditividad tenemos que la medida de  $S_k$  está acotada por

$$\mu(S_k) \leq 2^{-k} + 2^{-k-1} + 2^{-k-2} + \dots = 2^{1-k}$$

y en consecuencia la medida de  $S$  es

$$\mu(S) = \lim_{k \rightarrow \infty} \mu(S_k) = 0.$$

Veamos que si  $\omega \in \Omega - S$  entonces  $X_{n_k}(\omega) \rightarrow X(\omega)$ . Sea  $\varepsilon > 0$ , escogemos  $K$  de modo que  $2^{-K} < \varepsilon$  y  $\omega \notin S_K$ . Entonces para todo  $k \geq K$ ,  $\omega \notin S_k$  y en consecuencia

$$|X_{n_k}(\omega) - X(\omega)| < 2^{-k} < \varepsilon.$$

■

**Corolario 1.1**  $X_n$  converge en medida a  $X$  si y sólo si cada subsucesión  $(X_{n_k})$  contiene una subsucesión  $(X_{n_{k_i}})$  que converge a  $X$  c.s.

**Demostración.** Si  $X_n \xrightarrow{\mu} X$  y  $(X_{n_k})$  es una subsucesión, entonces  $X_{n_k} \xrightarrow{\mu} X$  y por el teorema anterior existe una subsucesión  $(X_{n_{k_i}})$  que converge a  $X$  c.s.

Recíprocamente, supongamos que toda subsucesión tiene una subsucesión que converge c.s. a  $X$  y supongamos que  $X_n$  no converge a  $X$  en probabilidad para obtener una contradicción.

Si  $X_n$  no converge en probabilidad a  $X$ , existen una subsucesión  $(X_{n_k})$ ,  $\delta > 0$  y  $\varepsilon > 0$  tales que

$$\mu(|X_{n_k} - X| > \varepsilon) \geq \delta. \quad (1.1)$$

Pero esta subsucesión  $(X_{n_k})$  debería tener una subsucesión que converge c.s. a  $X$  y por lo tanto en probabilidad. Esto contradice a (1.1). ■

**Corolario 1.2** a) Si  $X_n \rightarrow X$  c.s. y  $g : \mathbb{R} \rightarrow \mathbb{R}$  es continua entonces  $g(X_n) \rightarrow g(X)$  c.s.

b) Si  $X_n \xrightarrow{\mu} X$  y  $g : \mathbb{R} \rightarrow \mathbb{R}$  es continua entonces  $g(X_n) \xrightarrow{\mu} g(X)$ .

**Demostración.** (a) Existe un conjunto nulo  $N \in \mathcal{F}$  tal que si  $\omega \notin N$  entonces  $X_n(\omega) \rightarrow X(\omega)$  en  $\mathbb{R}$ . Por continuidad de  $g$ , si  $\omega \notin N$ ,

$$g(X_n(\omega)) \rightarrow g(X(\omega)),$$

es decir,  $(g(X_n))$  converge c.s. a  $g(X)$ .

(b) Sea  $(g(X_{n_k}))$  una subsucesión de  $(g(X_n))$ . Basta hallar una subsucesión  $(g(X_{n_{k_i}}))$  que sea c.s. convergente. Sabemos que  $(X_{n_k})$  tiene una subsucesión c.s. convergente  $(X_{n_{k_i}})$  que converge a  $X$ . Por lo tanto  $g(X_{n_{k_i}}) \rightarrow g(X)$  c.s. ■

**Corolario 1.3 (de Convergencia Dominada de Lebesgue)** Si  $X_n \xrightarrow{\mu} X$  y existe una función medible  $Y \in L^1$  tal que  $|X_n| \leq Y$ , entonces

$$\int X_n d\mu \rightarrow \int X d\mu.$$

**Demostración.** Como las integrales forman una sucesión de números reales, basta demostrar que toda subsucesión convergente de  $\int X_n d\mu$  converge a  $\int X d\mu$ .

Supongamos que  $\int X_{n_k} d\mu$  converge. Por hipótesis tenemos convergencia en medida y en consecuencia  $(X_{n_k})$  tiene una subsucesión  $(X_{n_{k_i}})$  que converge c.s. a  $X$ . Por el TCD tenemos que

$$\int X_{n_{k_i}} d\mu \rightarrow \int X d\mu$$

En consecuencia  $\int X_{n_k} d\mu \rightarrow \int X d\mu$ . ■

**Proposición 1.4 (Propiedades)** Si  $X_n \xrightarrow{\mu} X$  y  $Y_n \xrightarrow{\mu} Y$

$$1. X_n + Y_n \xrightarrow{\mu} X + Y.$$

$$2. X_n Y_n \xrightarrow{\mu} XY.$$

**Demostración.** (1) Observamos que

$$\{|(X_n + Y_n) - (X + Y)| > \varepsilon\} \subset \{|X_n - X| > \frac{\varepsilon}{2}\} \cup \{|Y_n - Y| > \frac{\varepsilon}{2}\}.$$

Tomando medidas, usando subaditividad y haciendo  $n \rightarrow \infty$  se obtiene el resultado.

(2) Basta demostrar que para toda subsucesión  $(n_k)$  existe una subsucesión  $n_{k_i}$  tal que

$$X_{n_{k_i}} Y_{n_{k_i}} \xrightarrow{c.s.} XY.$$

Como  $X_{n_k} \xrightarrow{\mu} X$ , existe una subsucesión  $(n'_k)$  tal que

$$X_{n'_k} \xrightarrow{c.s.} X.$$

Como  $Y_n \xrightarrow{\mu} Y$ , dada la subsucesión  $(n'_k)$ , existe una subsucesión  $(n'_{k_i})$  tal que

$$X_{n'_{k_i}} \xrightarrow{c.s.} X, \quad Y_{n'_{k_i}} \xrightarrow{c.s.} Y,$$

y en consecuencia tenemos

$$X_{n'_{k_i}} Y_{n'_{k_i}} \xrightarrow{c.s.} XY.$$

Por lo tanto, toda subsucesión de  $(X_n Y_n)$  tiene una subsucesión que converge c.s. ■

**Proposición 1.5 (Ley Débil de Grandes Números)** Si  $(X_n, n \geq 1)$  son i.i.d. con  $E(X_n) = \mu$  y  $\text{Var}(X_n) = \sigma^2$ , entonces

$$\frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{P} \mu$$

**Demostración.** Basta usar la desigualdad de Chebyshef. ■

## 1.4. Convergencia en $L^p$

En esta sección estudiamos un nuevo tipo de convergencia que tiene gran importancia en el análisis funcional. Recordemos que una función medible  $X$  pertenece al espacio  $L^p$  si  $\int |X|^p d\mu < \infty$ . Para  $p \geq 1$  y  $X, Y \in L^p$  definimos una distancia en este espacio por

$$d_p(X, Y) = \left( \int |X - Y|^p d\mu \right)^{1/p}.$$

Para ver que  $d_p$  es una distancia demostraremos más adelante la desigualdad triangular, que se conoce como la desigualdad de Minkowski. Por otro lado, es claro que  $d_p(X, Y) = d_p(Y, X)$ . Además si  $X = Y$  tenemos que  $d_p(X, Y) = 0$  pero el recíproco no es cierto: Si  $d_p(X, Y) = 0$  sólo podemos concluir que  $X \stackrel{c.s.}{=} Y$ . Por lo tanto  $d_p$  sólo será una *pseudo-distancia*.

Para tener una distancia podemos tomar la relación de equivalencia  $X \stackrel{c.s.}{=} Y$  sobre el espacio  $L^p$  y en lugar de considerar las funciones medibles  $X$  consideramos las clases de equivalencia  $\tilde{X}$ . El espacio cociente, formado por las clases de equivalencia, lo denotamos  $\mathcal{L}^p$  y  $d_p$  si será una distancia sobre este espacio. En lo que sigue vamos a obviar este procedimiento y hablaremos de  $d_p$  como una distancia sobre el espacio  $L^p$ .

Hay una norma que induce esta distancia:

$$\|X\|_p = \left( \int |X|^p \right)^{1/p}.$$

**Definición 1.6** Decimos que la sucesión  $(X_n, n \geq 1)$  converge a  $X$  en  $L^p$  si todas las variables están en  $L^p$  y

$$\int |X_n - X|^p d\mu \rightarrow 0$$

cuando  $n \rightarrow \infty$ . Usamos la notación

$$X_n \xrightarrow{L^p} X.$$

**Proposición 1.6** *Convergencia en  $L^p$  implica convergencia en medida.*

**Demostración.** Tenemos

$$\begin{aligned} \mu(|X_n - X| \geq \varepsilon) &= \int \mathbf{1}_{\{|X_n - X| > \varepsilon\}} d\mu \\ &= \int \mathbf{1}_{\{|X_n - X|^p > \varepsilon^p\}} d\mu \\ &\leq \int \frac{|X_n - X|^p}{\varepsilon^p} \mathbf{1}_{\{|X_n - X|^p > \varepsilon^p\}} d\mu \\ &\leq \frac{1}{\varepsilon^p} \int |X_n - X|^p d\mu \rightarrow 0 \end{aligned}$$

cuando  $n \rightarrow \infty$ . ■

El siguiente ejemplo muestra que el recíproco no es cierto.

#### Ejemplo 1.4

De nuevo, el espacio de medida es el espacio de probabilidad de Lebesgue  $([0, 1], \mathcal{B}, \lambda)$  y definimos

$$X_n = 2^n \mathbf{1}_{(0, \frac{1}{n})}.$$

Entonces

$$P(|X_n| > \varepsilon) = \lambda\left(\left(0, \frac{1}{n}\right)\right) = \frac{1}{n} \rightarrow 0$$

pero

$$E(|X_n|^p) = 2^{np} \frac{1}{n} \rightarrow \infty.$$

Convergencia en  $L^p$  no implica convergencia c.s., como lo muestra el ejemplo 1.2. Para cualquier  $p > 0$ , como la variable  $X_n$  sólo toma valores 0 ó 1, el valor esperado  $E(|X_n|^p)$  es igual a la longitud del intervalo correspondiente a  $X_n$ , y esta longitud tiende a 0.

Convergencia casi segura tampoco implica convergencia en  $L^p$ , como lo muestra el ejemplo 1.3. Aún cuando la medida del espacio sea finita, es posible dar ejemplo de sucesiones que convergen c.s. pero no convergen en  $L^p$ .

#### 1.4.1. Desigualdades

**Teorema 1.2 (Desigualdad de Hölder)** *Sea  $p, q$  números reales tales que  $p, q > 1$  y*

$$\frac{1}{p} + \frac{1}{q} = 1. \tag{1.2}$$

*Sean  $X \in L^p, Y \in L^q$ , entonces el producto  $XY$  es integrable y*

$$\int |XY| d\mu \leq \left( \int |X|^p d\mu \right)^{1/p} \left( \int |Y|^q d\mu \right)^{1/q}. \tag{1.3}$$

En términos de las normas la desigualdad dice que

$$\|XY\|_1 \leq \|X\|_p \|Y\|_q.$$

Si  $p$  y  $q$  satisfacen (1.2) decimos que son *conjugados*.

**Demostración.** Observamos inicialmente que si  $\int |X|^p d\mu = 0$  entonces  $X = 0$  c.s. y en consecuencia  $\int |XY| d\mu = 0$ , de modo que la desigualdad es cierta. Algo similar ocurre si  $\int |Y|^q d\mu = 0$ , así que podemos suponer que el lado derecho de (1.3) es estrictamente positivo.

Dados  $a > 0, b > 0$ , existen  $s, t \in \mathbb{R}$  tales que

$$a = \exp\{s/p\}, \quad b = \exp\{t/q\}.$$

Como la función exponencial es convexa y  $p^{-1} + q^{-1} = 1$  tenemos que

$$\exp\{p^{-1}s + q^{-1}t\} \leq p^{-1} \exp\{s\} + q^{-1} \exp\{t\},$$

y usando la definición de  $s, t$ ,

$$ab \leq p^{-1}a^p + q^{-1}b^q.$$

Ahora reemplazamos  $a$  por  $|X|/\|X\|_p$  y  $b$  por  $|Y|/\|Y\|_q$  y obtenemos

$$\frac{|XY|}{\|X\|_p \|Y\|_q} \leq p^{-1} \left( \frac{|X|}{\|X\|_p} \right)^p + q^{-1} \left( \frac{|Y|}{\|Y\|_q} \right)^q.$$

Finalmente, tomando integrales,

$$\frac{1}{\|X\|_p \|Y\|_q} \int |XY| d\mu \leq p^{-1} + q^{-1} = 1$$

■

**Teorema 1.3 (Desigualdad de Minkowski)** *Supongamos que  $X, Y \in L^p$  para  $1 \leq p < \infty$ . Entonces  $X + Y \in L^p$  y*

$$\|X + Y\|_p \leq \|X\|_p + \|Y\|_p.$$

**Demostración.** La desigualdad

$$|X + Y|^p \leq 2(|X|^p \vee |Y|^p) \leq 2(|X|^p + |Y|^p) \in L^p$$

muestra que los espacios  $L^p$ ,  $p \geq 1$  son cerrados aditivamente. Si  $p = 1$  la desigualdad de Minkowski sigue de la desigualdad triangular usual. Sea  $1 < p < \infty$  y escojamos  $q$  conjugado de  $p$  de modo que  $p^{-1} + q^{-1} = 1$ , es decir,  $p - 1 = p/q$ . Usando la desigualdad de Hölder,

$$\begin{aligned} \|X + Y\|_p^p &= \int |X + Y|^p d\mu = \int |X + Y| |X + Y|^{p/q} d\mu \\ &\leq \int |X| |X + Y|^{p/q} d\mu + \int |Y| |X + Y|^{p/q} d\mu \\ &\leq \|X\|_p \| |X + Y|^{p/q} \|_q + \|Y\|_p \| |X + Y|^{p/q} \|_q \\ &= (\|X\|_p + \|Y\|_p) \| |X + Y|^{p/q} \|_q \\ &= (\|X\|_p + \|Y\|_p) \left( \int |X + Y|^p d\mu \right)^{1/q} \\ &= (\|X\|_p + \|Y\|_p) \|X + Y\|_p^{p/q} \\ &= (\|X\|_p + \|Y\|_p) \|X + Y\|_p^{p-1}. \end{aligned}$$

Si el último factor es distinto de 0, podemos dividir por él para obtener el resultado. Si es igual a 0, ambos lados de la desigualdad valen 0. ■

La desigualdad anterior es la desigualdad triangular para  $\|\cdot\|_p$ .

**Teorema 1.4 (Desigualdad de Jensen)** Sea  $(\Omega, \mathcal{F}, P)$  un espacio de probabilidad,  $g : \mathbb{R} \rightarrow \mathbb{R}$  una función convexa y  $X$  una variable aleatoria integrable tal que  $g(X)$  también es integrable. Entonces

$$E(g(X)) \geq g(E(X)).$$

**Demostración.** Sea  $g$  una función convexa, sabemos que dado cualquier punto de la gráfica de  $g$  podemos hallar (al menos) una recta que es tangente a la curva en ese punto y tal que la recta siempre está por debajo de la curva que representa a  $g$ . Esta recta (que en general no es única) se conoce como la recta de soporte de  $g$ . Sea  $r(x) = ax + b$  la recta de soporte de  $g$  en el punto  $(E(X), g(E(X)))$  sobre la gráfica de función  $g$ . Entonces

$$aX(\omega) + b \leq g(X(\omega)).$$

Tomando esperanza obtenemos

$$aE(X) + b \leq E(g(X)).$$

Pero como la recta  $r(x)$  es tangente a la función  $g$  en  $(E(X), g(E(X)))$ ,  $aE(X) + b = g(E(X))$ . ■

**Ejemplo 1.5 (Desigualdad de Lyapunov)**

Sea  $(\Omega, \mathcal{F}, P)$  un espacio de probabilidad,  $X$  una variable aleatoria y  $0 < \alpha < \beta$ . Definimos

$$r = \frac{\beta}{\alpha} > 1, \quad s = \frac{\beta}{\beta - \alpha}.$$

Entonces

$$\frac{1}{r} + \frac{1}{s} = \frac{\alpha}{\beta} + \frac{\beta - \alpha}{\beta} = 1.$$

Ahora ponemos  $Z = |X|^\alpha$ ,  $Y = 1$  usamos la desigualdad de Hölder:

$$E(|ZY|) \leq (E|Z|^r)^{1/r} (E|Y|^s)^{1/s},$$

es decir

$$E(|X|^\alpha) \leq (E|X|^{r\alpha})^{1/r} 1 = (E|X|^\beta)^{\alpha/\beta}$$

de modo que

$$(E(|X|^\alpha))^{1/\alpha} \leq (E|X|^\beta)^{1/\beta}$$

y

$$\|X\|_\alpha \leq \|X\|_\beta.$$

Concluimos que  $X \in L^\beta \Rightarrow X \in L^\alpha$  si  $\alpha < \beta$ . Más aún,  $\|X\|_\alpha = (E(|X|^\alpha))^{1/\alpha}$  es no-decreciente en  $\alpha$ . Como consecuencia tenemos que si  $X_n \xrightarrow{L^p} X$  y  $r < p$ ,  $X_n \xrightarrow{L^r} X$ .

Antes de presentar el siguiente resultado recordamos el lema de Fatou, que usaremos en la próxima demostración.

**Lema 1.1 (Lema de Fatou)** Si  $X_n \geq 0$  para  $n \geq 1$  entonces

$$E(\liminf_n X_n) \leq \liminf_n E(X_n),$$

y en particular si  $X_n \rightarrow X$  c.p.1,

$$E(X) \leq \liminf_n E(X_n).$$

**Teorema 1.5** Para  $p \geq 1$  el espacio  $L^p$  es completo, es decir, si  $(X_n)$  es una sucesión de Cauchy en  $L^p$ , existe  $X \in L^p$  tal que  $X_n \xrightarrow{L^p} X$ .

**Demostración.** Sea  $(X_n)$  una sucesión de Cauchy en  $L^p$ . Dado  $\varepsilon > 0$  sea  $N = N(\varepsilon) \in \mathbb{N}$  tal que si  $n, m \geq N$ ,

$$\int |X_n - X_m|^p d\mu < \varepsilon^{p+1}. \quad (1.4)$$

Llamemos  $N_k = N(\varepsilon 2^{-k})$  y supongamos que  $N_{k+1} > N_k$  para todo  $k$ . Definimos los conjuntos

$$A(\varepsilon, m, n) = \{\omega : |X_m(\omega) - X_n(\omega)| \geq \varepsilon\}$$

entonces

$$\int |X_n - X_m|^p d\mu \geq \int_{A(\varepsilon, m, n)} |X_n - X_m|^p \geq \varepsilon^p \mu(A(\varepsilon, m, n)) \quad (1.5)$$

y combinando (1.4) y (1.5) obtenemos  $\mu(A(\varepsilon, m, n)) < \varepsilon$  si  $m, n \geq N(\varepsilon)$ .

Sea ahora  $A_k = A(\varepsilon 2^{-k}, N_{k+1}, N_k)$ ,  $B_k = \cup_{i \geq k} A_i$ , tenemos  $\mu(A_k) < 2^{-k} \varepsilon$ ,  $\mu(B_k) < 2^{1-k} \varepsilon$  y si  $\omega \notin B_k$

$$|X_{N_{i+1}}(\omega) - X_{N_i}(\omega)| < \varepsilon 2^{-i} \quad \text{para todo } i \geq k.$$

Por lo tanto la serie  $\sum_i (X_{N_{i+1}} - X_{N_i})$  converge fuera de  $B = \cap_{k \geq 1} B_k$  y  $\mu(B) = 0$ . En consecuencia existe  $X$  tal que  $X_{N_i} \rightarrow X$  c.s.

Para un entero fijo  $r$  ponemos  $Y_i = |X_{N_i} - X_r|^p$ ,  $Y = |X - X_r|^p$  y obtenemos una sucesión  $Y_i$  de funciones medibles no-negativas con  $\liminf Y_i = \lim Y_i = Y$  c.s. Por el lema de Fatou tenemos

$$\int Y d\mu \leq \liminf_{i \rightarrow \infty} \int |X_{N_i} - X_r|^p d\mu < \varepsilon$$

si  $r > N(\varepsilon)$ . En consecuencia  $Y$  es integrable, es decir  $(X - X_r) \in L^p$ , lo cual implica que  $X \in L^p$ . Además probamos que

$$\int |X - X_r|^p d\mu < \varepsilon \quad \text{si } r > N(\varepsilon)$$

de modo que  $X_r \xrightarrow{L^p} X$ . ■

**Observación 1.2** Es importante resaltar que el resultado anterior es falso para la integral de Riemann sobre intervalos finitos. No es difícil construir ejemplos de sucesiones de funciones cuyas potencias de orden  $p$  son integrables según Riemann, que son de Cauchy en  $L^p$  pero cuyo límite es discontinuo en un conjunto de medida positiva y por lo tanto no pueden ser integrables según Riemann.

Como consecuencia del teorema anterior observamos que los espacios  $L^p$  son espacios normados que son completos respecto a la métrica inducida por la norma. Un espacio con estas propiedades se conoce como un *espacio de Banach*.

Si  $p > 1$  y  $q > 1$  son conjugados decimos que los espacios  $L^p$  y  $L^q$  son conjugados. Por la desigualdad de Hölder sabemos que si  $X \in L^p$  y  $Y \in L^q$  entonces el producto  $XY$  es integrable. Observamos que el conjugado de  $p = 2$  es  $q = 2$ , es decir que  $L^2$  es su propio espacio conjugado, y además es el único caso en el que esto ocurre. Esto quiere decir que si tomamos dos funciones de  $L^2$ , su producto es integrable, y por lo tanto podemos definir un producto interno en  $L^2$ : Para  $X, Y \in L^2$ ,

$$\langle X, Y \rangle = \int XY d\mu.$$

Es fácil ver que esta definición satisface las condiciones de un producto interno (pasando al espacio cociente  $\mathcal{L}^2$  si es necesario). Además, la norma asociada a este producto interno es la norma  $\|\cdot\|_2$ , que definimos anteriormente, ya que

$$\langle X, X \rangle = \int |X|^2 d\mu = \|X\|_2^2.$$

Por lo tanto  $L^2$  es un espacio de Banach que tiene un producto interno que induce la norma del espacio. Un espacio con estas propiedades se conoce como un *espacio de Hilbert*.

## 1.5. Convergencia en Distribución

**Definición 1.7** Si  $F$  es una f.d. definimos el *conjunto de puntos de continuidad* o *conjunto de continuidad* de  $F$  por

$$\mathcal{C}(F) = \{x \in \mathbb{R} : F \text{ es continua en } x\}$$

Un intervalo finito  $I$  con extremos  $a < b$  es un *intervalo de continuidad* para  $F$  si  $a, b \in \mathcal{C}(F)$ .

**Definición 1.8** Sea  $(X_n, n \geq 1)$  una sucesión de v.a. con f.d.  $F_{X_n}$ ,  $n \geq 1$ .  $X_n$  converge en distribución a la v.a.  $X$  cuando  $n \rightarrow \infty$  si

$$F_{X_n}(x) \rightarrow F_X(x) \quad \text{cuando } n \rightarrow \infty, \quad \forall x \in \mathcal{C}(F_X).$$

Notación:  $X_n \xrightarrow{d} X$  o  $X_n \xrightarrow{w} X$  cuando  $n \rightarrow \infty$ .

**Observación 1.3** Como en esta definición sólo intervienen las funciones de distribuciones, las variables no necesariamente están definidas en un mismo espacio de probabilidad.

Abusando la notación, escribiremos  $X_n \xrightarrow{w} \mathcal{N}(0, 1)$  en lugar de  $X_n \xrightarrow{w} X$  cuando  $n \rightarrow \infty$  donde  $X \sim \mathcal{N}(0, 1)$ .

### Ejemplo 1.6

Sea  $X_n \sim \delta_{1/n}$ , es decir, la delta de Dirac concentrada en el punto  $1/n$ . Si la definición 1.8 tiene sentido deberíamos tener  $X_n \xrightarrow{d} \delta_0$  cuando  $n \rightarrow \infty$ . Tenemos

$$F_{X_n}(x) = \begin{cases} 0, & \text{si } x < 1/n, \\ 1, & \text{si } x \geq 1/n, \end{cases} \quad \rightarrow \quad \begin{cases} 0, & \text{si } x \leq 0, \\ 1, & \text{si } x > 0. \end{cases}$$

Por lo tanto  $F_{X_n} \rightarrow F_{\delta_0}(x)$  cuando  $n \rightarrow \infty$  para todo  $x \in \mathcal{C}(F_{\delta_0})$  pero no para todo  $x$ . Si en cambio tuviéramos  $Y_n \sim \delta_{-1/n}$  entonces

$$F_{Y_n}(x) = \begin{cases} 0, & \text{si } x < -1/n, \\ 1, & \text{si } x \geq -1/n, \end{cases} \quad \rightarrow \quad \begin{cases} 0, & \text{si } x < 0, \\ 1, & \text{si } x \geq 1/n. \end{cases}$$

y en este caso si tenemos convergencia para todo  $x$ .

**Teorema 1.6** Sean  $X$  y  $X_n$ ,  $n \geq 1$  v.a. Si  $X_n \xrightarrow{P} X$  entonces  $X_n \xrightarrow{d} X$ .

**Demostración.** Sea  $\varepsilon > 0$ , entonces

$$\begin{aligned} F_{X_n}(x) &= P(X_n \leq x) = P(X_n \leq x, |X_n - X| \leq \varepsilon) + P(X_n \leq x, |X_n - X| > \varepsilon) \\ &\leq P(X \leq x + \varepsilon, |X_n - X| \leq \varepsilon) + P(|X_n - X| > \varepsilon) \\ &\leq P(X \leq x + \varepsilon) + P(|X_n - X| > \varepsilon), \end{aligned}$$

y por la convergencia en probabilidad

$$\limsup_{n \rightarrow \infty} F_{X_n}(x) \leq F_X(x + \varepsilon).$$

De manera similar, cambiando  $X_n$  por  $X$ ,  $x$  por  $x - \varepsilon$ ,  $X$  por  $X_n$  y  $x + \varepsilon$  por  $x$ , sigue que

$$\liminf_{n \rightarrow \infty} F_{X_n}(x) \geq F_X(x - \varepsilon).$$

Estas dos relaciones valen para todo  $x$  y todo  $\varepsilon > 0$ . Suponiendo ahora que  $x \in \mathcal{C}(F_X)$  y haciendo  $\varepsilon \rightarrow 0$  obtenemos que

$$F_X(x) = F_X(x^-) \leq \liminf_{n \rightarrow \infty} F_{X_n}(x) \leq \limsup_{n \rightarrow \infty} F_{X_n}(x) \leq F_X(x).$$

■

**Observación 1.4** Si  $F_X$  tiene un salto en  $x$ , sólo podemos concluir que

$$F_X(x^-) \leq \liminf_{n \rightarrow \infty} F_{X_n}(x) \leq \limsup_{n \rightarrow \infty} F_{X_n}(x) \leq F_X(x).$$

Como  $F_X(x) - F_X(x^-)$  es el tamaño del salto no es posible obtener convergencia en un salto.

**Ejemplo 1.7**

Sea  $N \sim \mathcal{N}(0, 1)$ , de modo que la distribución es simétrica. Definimos  $X_n = (-1)^n N$  para  $n \geq 1$ , entonces  $X_n \stackrel{d}{=} N$  de modo que  $X_n \xrightarrow{d} N$ , pero  $(X_n)$  no converge ni c.s. ni en probabilidad.

**Ejemplo 1.8**

Para  $\alpha > 0$  sea  $X_n$ ,  $n \geq 1$  una sucesión de v.a.i. tales que

$$P(X_n = 0) = 1 - \frac{1}{n^\alpha} \quad y \quad P(X_n = n) = \frac{1}{n^\alpha}$$

Los siguientes resultados son ciertos:

$$\begin{array}{lll} X_n \xrightarrow{P} 0 & (n \rightarrow \infty) & \text{aún sin independencia} \\ X_n \xrightarrow{c.s.} 0 & (n \rightarrow \infty) & \text{sii } \alpha > 1 \\ X_n \xrightarrow{L^p} 0 & (n \rightarrow \infty) & \text{sii } \alpha > p \end{array}$$

La convergencia en probabilidad es consecuencia de:

$$P(|X_n| > \varepsilon) = P(X_n = n) = \frac{1}{n^\alpha} \rightarrow 0 \quad \text{cuando } n \rightarrow \infty.$$

La convergencia con probabilidad 1 sigue del Lema de Borel-Cantelli ya que

$$\sum_{n=1}^{\infty} P(|X_n| > \varepsilon) \begin{cases} < \infty & \text{cuando } \alpha > 1, \\ = \infty & \text{cuando } \alpha \leq 1, \end{cases}$$

En cuanto a la convergencia en  $L^p$

$$E|X_n|^p = 0^p \cdot \left(1 - \frac{1}{n^\alpha}\right) + n^p \cdot \frac{1}{n^\alpha} = n^{p-\alpha} \begin{cases} \rightarrow 0, & \text{para } p < \alpha, \\ = 1, & \text{para } p = \alpha, \\ \rightarrow \infty, & \text{para } p > \alpha. \end{cases} \quad \text{cuando } n \rightarrow \infty,$$

Observamos que  $E|X|^p$  ni converge a 0 ni diverge a infinito cuando  $p = \alpha$ , sino que es igual a 1.

**Teorema 1.7** Sea  $(X_n, n \geq 1)$  una sucesión de v.a.i. y  $c$  una constante, entonces

$$X_n \xrightarrow{d} \delta_c \quad (n \rightarrow \infty) \quad \Leftrightarrow \quad X_n \xrightarrow{P} c \quad (n \rightarrow \infty).$$

**Demostración.** Supongamos que  $X_n \xrightarrow{d} \delta_c$  cuando  $n \rightarrow \infty$  y sea  $\varepsilon > 0$ . Si  $c - \varepsilon, c + \varepsilon \in \mathcal{C}(F_X)$  entonces

$$\begin{aligned} P(|X_n - c| > \varepsilon) &= 1 - P(c - \varepsilon \leq X_n \leq c + \varepsilon) \\ &= 1 - F_{X_n}(c + \varepsilon) + F_{X_n}(c - \varepsilon) - P(X_n = c - \varepsilon) \\ &\leq 1 - F_{X_n}(c + \varepsilon) + F_{X_n}(c - \varepsilon) \\ &\rightarrow 0 \quad \text{cuando } n \rightarrow \infty, \end{aligned}$$

ya que  $F_{X_n}(c + \varepsilon) \rightarrow F_X(c + \varepsilon) = 1$ ,  $F_{X_n}(c - \varepsilon) \rightarrow F_X(c - \varepsilon) = 0$ ,. ■

### 1.5.1. Caracterización de la Convergencia en Distribución

**Lema 1.2 (Lema de Aproximación)** *Sea  $f$  una función a valores reales tal que se cumple alguna de las siguientes condiciones:*

- $f \in \mathcal{C}_0$  (funciones continuas que se anulan en  $\pm\infty$ ),
- $f \in \mathcal{C}[a, b]$  para  $a, b \in \mathbb{R}$ ,

entonces, para cada  $\varepsilon > 0$  existe una función simple  $g$  tal que

$$\sup_x |f(x) - g(x)| < \varepsilon.$$

**Teorema 1.8** *Sea  $\{X_n, n \geq 1\}$  una sucesión de v.a. y supongamos que  $X_n \xrightarrow{d} X$  cuando  $n \rightarrow \infty$ . Si  $h$  es una función continua a valores reales o complejos definida en el intervalo acotado  $[a, b]$ , donde  $a, b \in \mathcal{C}(F_X)$ , entonces*

$$\mathbb{E}h(X_n) \rightarrow \mathbb{E}h(X) \quad \text{cuando } n \rightarrow \infty. \quad (1.6)$$

**Demostración.** El caso complejo sigue del caso real. Usaremos el lema de aproximación. Sea  $A \subset \mathcal{C}(F_X) \subset \mathbb{R}$  un subconjunto denso numerable. Si  $h(x) = \mathbf{1}_{(c,d]}$  para  $c, d \in A$ ,  $a \leq c < d \leq b$ , (1.6) se reduce a demostrar que  $P(c < X_n \leq d) \rightarrow P(c < X \leq d)$ , lo cual es cierto por hipótesis. Por linealidad la conclusión vale para funciones escalera cuyos 'escalones' tengan extremos en  $A$ . Sea ahora  $h \in \mathcal{C}[a, b]$ , y sea  $g$  una función simple aproximante, entonces usando la desigualdad de Jensen,

$$\begin{aligned} |\mathbb{E}h(X_n) - \mathbb{E}h(X)| &\leq |\mathbb{E}h(X_n) - \mathbb{E}g(X_n)| + |\mathbb{E}g(X_n) - \mathbb{E}g(X)| + |\mathbb{E}g(X) - \mathbb{E}h(X)| \\ &\leq \mathbb{E}|h(X_n) - g(X_n)| + |\mathbb{E}g(X_n) - \mathbb{E}g(X)| + \mathbb{E}|g(X) - h(X)| \\ &\leq \varepsilon + |\mathbb{E}g(X_n) - \mathbb{E}g(X)| + \varepsilon. \end{aligned}$$

Como ya hemos visto que para funciones simples el término central tiende a cero cuando  $n \rightarrow \infty$  obtenemos

$$\limsup_{n \rightarrow \infty} |\mathbb{E}h(X_n) - \mathbb{E}h(X)| < 2\varepsilon,$$

lo cual demuestra el teorema. ■

**Teorema 1.9** *Sea  $\{X_n, n \geq 1\}$  una sucesión de v.a. y supongamos que  $X_n \xrightarrow{d} X$  cuando  $n \rightarrow \infty$ . Si  $h$  es una función a valores reales o complejos, continua y acotada, entonces*

$$\mathbb{E}h(X_n) \rightarrow \mathbb{E}h(X) \quad \text{cuando } n \rightarrow \infty. \quad (1.7)$$

**Demostración.** De nuevo, el caso complejo sigue del caso real. Supongamos que  $|h(x)| \leq M$  para todo  $x$  y sea  $K > 0$ , entonces

$$\begin{aligned} |\mathbb{E}h(X_n) - \mathbb{E}h(X)| &\leq |\mathbb{E}h(X_n)\mathbf{1}_{\{|X_n| \leq K\}} - \mathbb{E}h(X)\mathbf{1}_{\{|X| \leq K\}}| + |\mathbb{E}h(X_n)\mathbf{1}_{\{|X_n| > K\}}| + |\mathbb{E}h(X)\mathbf{1}_{\{|X| > K\}}| \\ &\leq |\mathbb{E}h(X_n)\mathbf{1}_{\{|X_n| \leq K\}} - \mathbb{E}h(X)\mathbf{1}_{\{|X| \leq K\}}| + \mathbb{E}|h(X_n)|\mathbf{1}_{\{|X_n| > K\}} + \mathbb{E}|h(X)|\mathbf{1}_{\{|X| > K\}} \\ &\leq |\mathbb{E}h(X_n)\mathbf{1}_{\{|X_n| \leq K\}} - \mathbb{E}h(X)\mathbf{1}_{\{|X| \leq K\}}| + MP(|X_n| > K) + MP(|X| > K) \end{aligned}$$

Sea  $\varepsilon > 0$  y escojamos  $K \in \mathcal{C}(F_X)$  suficientemente grande como para que  $2MP(|X| > K) < \varepsilon$ . Usando el teorema 1.8 para el primer término y la convergencia en distribución para el segundo, obtenemos que

$$\limsup_{n \rightarrow \infty} |\mathbb{E}h(X_n) - \mathbb{E}h(X)| < 2MP(|X| > K) < \varepsilon.$$

■

**Teorema 1.10** Sea  $\{X_n, n \geq 1\}$  una sucesión de v.a. Entonces  $X_n \xrightarrow{d} X$  cuando  $n \rightarrow \infty$  si y sólo si

$$Eh(X_n) \rightarrow Eh(X) \quad \text{cuando } n \rightarrow \infty. \quad (1.8)$$

para toda función real continua y acotada.

**Demostración.** Por el teorema 1.9 basta demostrar la suficiencia. Sean  $a, b \in \mathcal{C}(F)$ ,  $-\infty < a < b < \infty$ . Ponemos

$$g_k(x) = \begin{cases} 0 & \text{para } x < a - \delta_k, \\ \frac{x - (a - \delta_k)}{\delta_k} & \text{para } x \in [a - \delta_k, a], \\ 1 & \text{para } x \in [a, b], \\ \frac{b + \delta_k - x}{\delta_k} & \text{para } x \in [b, b + \delta_k], \\ 0 & \text{para } x > b + \delta_k \end{cases}$$

con  $\delta_k \downarrow 0$  cuando  $k \rightarrow \infty$  y observamos que  $\mathbf{1}_{(a,b]}(x) \leq g_k(x)$ . Supongamos que (1.8) vale. Por la monotonía de la función de distribución y el teorema 1.9 obtenemos

$$F_n(a, b] = \int_a^b dF_n(x) \leq \int g_k(x) dF_n(x) \leq E g_k(X_n) \rightarrow E g_k(X) \quad \text{cuando } n \rightarrow \infty.$$

Haciendo  $n \rightarrow \infty$

$$\limsup_{n \rightarrow \infty} F_n(a, b] \leq E g_k(X) \leq F([a - \delta_k, b + \delta_k]).$$

Haciendo ahora  $k \rightarrow \infty$  tenemos  $\delta_k \rightarrow 0$  y  $g_k(x) \downarrow \mathbf{1}_{[a,b]}$ , y como  $a$  y  $b$  son puntos de continuidad concluimos que

$$\limsup_{n \rightarrow \infty} F_n(a, b] \leq F(a, b]. \quad (1.9)$$

Si, en cambio,

$$h_k(x) = \begin{cases} 0 & \text{para } x < a, \\ \frac{x - a}{\delta_k} & \text{para } x \in [a, a + \delta_k], \\ 1 & \text{para } x \in [a + \delta_k, b - \delta_k], \\ \frac{b - x}{\delta_k} & \text{para } x \in [b - \delta_k, b], \\ 0 & \text{para } x > b \end{cases}$$

los mismos argumentos nos dan

$$\liminf_{n \rightarrow \infty} F_n(a, b] \geq F([a + \delta_k, b - \delta_k]),$$

y como ahora  $h_k(x) \uparrow \mathbf{1}_{(a,b)}$ , tenemos finalmente

$$\liminf_{n \rightarrow \infty} F_n(a, b] \geq F(a, b]. \quad (1.10)$$

Las ecuaciones (1.9) y (1.10) demuestran que  $X_n \xrightarrow{d} X$  cuando  $n \rightarrow \infty$ . ■

Como corolario obtenemos los siguientes resultados:

**Corolario 1.4** Sea  $\{F_n, n \geq 0\}$  una familia de funciones de distribución y  $F$  también una f.d. Las siguientes afirmaciones son equivalentes

- (1)  $F_n \xrightarrow{d} F_0$ .
- (2) Para toda función real  $f$  acotada y uniformemente continua,

$$\int f dF_n \rightarrow \int f dF_0,$$

cuando  $n \rightarrow \infty$ .

Demostración. Basta observar que las funciones  $g_k$  y  $h_k$  que usamos en la demostración del teorema anterior son continuas con soporte compacto y por lo tanto son uniformemente continuas. ■

**Teorema 1.11** Sean  $X$  e  $Y$  v.a.

$$X \stackrel{d}{=} Y \Leftrightarrow E h(X) = E h(Y)$$

para toda función  $h$  continua y acotada.

**Teorema 1.12** Sean  $X$  y  $\{X_n, n \geq 1\}$  v.a. y supongamos que  $X_n \xrightarrow{d} X$  cuando  $n \rightarrow \infty$ . Entonces

$$E(|X|) \leq \liminf_{n \rightarrow \infty} E(|X_n|).$$

**Demostración.** Sea  $K \in \mathcal{C}(F_X)$  un número positivo. Por el teorema 1.8 tenemos

$$\liminf_{n \rightarrow \infty} E(|X_n|) \geq \liminf_{n \rightarrow \infty} E(|X_n| \mathbf{1}_{\{|X_n| \leq K\}}) = E(|X| \mathbf{1}_{\{|X| \leq K\}}).$$

La conclusión sigue haciendo  $K$  tender a infinito a través de una sucesión de puntos de continuidad de  $F_X$ . ■

## 1.6. Integrabilidad Uniforme

**Definición 1.9** Una sucesión de v.a.  $(X_n, n \geq 1)$  es *uniformemente integrable* si

$$E(|X_n| \mathbf{1}_{\{|X_n| > a\}}) \rightarrow 0 \quad \text{cuando } a \rightarrow \infty,$$

uniformemente en  $n$ .

**Notación:** Abreviaremos 'uniformemente integrable' por u.i.

Una manera equivalente de expresar la integrabilidad uniforme es a través de las funciones de distribución:  $\{X_n, n \geq 1\}$  es uniformemente integrable sii

$$\int_{|x| > a} |x| dF_{X_n}(x) \rightarrow 0 \quad \text{cuando } a \rightarrow \infty,$$

uniformemente en  $n$ .

**Observación 1.5** Si las variables  $X_n$  tienen media finita entonces  $E(|X_n| \mathbf{1}_{\{|X_n| > a\}}) \rightarrow 0$  cuando  $a \rightarrow \infty$ , para cada  $n$ , ya que las colas de integrales convergentes tienden a cero. La integrabilidad uniforme quiere decir que las colas tienden a cero de manera uniforme para todos los miembros de la sucesión.

Para cualquier sucesión de v.a.u.i.,

$$E|X_n| = E(|X_n| \mathbf{1}_{\{|X_n| \leq a\}}) + E(|X_n| \mathbf{1}_{\{|X_n| > a\}}) \leq a + 1,$$

para  $a$  suficientemente grande. Por lo tanto los momentos están acotados uniformemente. Sin embargo, la integrabilidad uniforme es más fuerte, como lo muestra el siguiente teorema.

**Teorema 1.13** Las variables  $X_n, n \geq 1$  son u.i. si y sólo si

$$(a) \sup_n E|X_n| < \infty,$$

(b) Para cualquier  $\varepsilon > 0$  existe  $\delta > 0$  tal que para cualquier conjunto  $A$  con  $P(A) < \delta$ ,

$$E(|X_n|\mathbf{1}_A) < \varepsilon \quad \text{uniformemente en } n.$$

**Demostración.** Supongamos que  $\{X_n, n \geq 1\}$  es u.i., sea  $A$  un conjunto tal que  $P(A) < \delta$ , donde  $\delta$  será escogido más adelante. Ya hemos verificado que los momentos son uniformemente acotados. Veamos (b):

$$\begin{aligned} E|X_n|\mathbf{1}_A &= E(|X_n|\mathbf{1}_{A \cap \{|X_n| \leq a\}}) + E(|X_n|\mathbf{1}_{A \cap \{|X_n| > a\}}) \\ &\leq aP(A) + E(|X_n|\mathbf{1}_{\{|X_n| > a\}}) \leq a\delta + \varepsilon/2 < \varepsilon, \end{aligned}$$

si escogemos primero  $a$  suficientemente grande como para que el segundo sumando sea menor que  $\varepsilon/2$  y luego  $\delta$  suficientemente pequeño como para que  $a\delta < \varepsilon/2$ .

Por otro lado, si se satisfacen las condiciones del teorema ponemos  $A_n = \{|X_n| > a\}$  y aplicamos la desigualdad de Markov y (a) para obtener

$$P(A_n) \leq \frac{E|X_n|}{a} \leq \frac{\sup_n E|X_n|}{a} < \delta$$

uniformemente en  $n$  para  $a$  suficientemente grande, lo cual, por (b), muestra que

$$E(|X_n|\mathbf{1}_{\{|X_n| > a\}}) = E(|X_n|\mathbf{1}_{A_n}) < \varepsilon$$

uniformemente en  $n$ , lo que demuestra la i.u. ■

A continuación presentamos algunos criterios suficientes para i.u.

**Teorema 1.14** Sea  $\{X_n, n \geq 1\}$  v.a. y supongamos que

$$\sup_n E(|X_n|^p) < \infty \quad \text{para algún } p > 1.$$

entonces  $\{X_n, n \geq 1\}$  es u.i. En particular esto es cierto si  $\{|X_n|^p, n \geq 1\}$  es u.i. para algún  $p > 1$ .

**Demostración.** Tenemos

$$\begin{aligned} E(|X_n|\mathbf{1}_{\{|X_n| > a\}}) &\leq a^{1-p} E(|X_n|^p \mathbf{1}_{\{|X_n| > a\}}) \leq a^{1-p} E(|X_n|^p) \\ &\leq a^{1-p} \sup_n E(|X_n|^p) \rightarrow 0 \quad \text{cuando } a \rightarrow \infty, \end{aligned}$$

uniformemente en  $n$ . ■

La siguiente generalización se demuestra de manera similar.

**Teorema 1.15** Sea  $\{X_n, n \geq 1\}$  v.a. y sea  $g$  una función no-negativa y creciente tal que  $g(x)/x \rightarrow \infty$  cuando  $x \rightarrow \infty$ . Si

$$\sup_n E(g(X_n)) < \infty,$$

entonces  $\{X_n, n \geq 1\}$  es u.i.

**Teorema 1.16** Sea  $\{X_n, n \geq 1\}$  v.a. tales que

$$|X_n| \leq Y \quad \text{c.s. para todo } n,$$

donde  $Y$  es una v.a. positiva integrable. Entonces  $\{X_n, n \geq 1\}$  es u.i.

**Demostración.** Basta observar que

$$\mathbb{E}(|X_n| \mathbf{1}_{\{|X_n|>a\}}) \leq \mathbb{E}(|Y| \mathbf{1}_{\{Y>a\}}) \rightarrow 0 \quad (a \rightarrow \infty),$$

uniformemente en  $n$ . ■

**Corolario 1.5** Sea  $\{X_n, n \geq 1\}$  una sucesión de v.a. Si

$$\mathbb{E}(\sup_n |X_n|) < \infty,$$

entonces  $\{X_n, n \geq 1\}$  es u.i.

**Ejemplo 1.9**

Sea  $X_i \in L^1$  para  $i = 1, \dots, n$  entonces el conjunto de v.a.  $\{X_1, \dots, X_n\}$  es uniformemente integrable ya que tenemos la siguiente acotación:

$$|X_i| \leq \sum_{i=1}^n |X_i| \in L^1$$

y por el teorema 1.16 el conjunto es u.i.

**Ejemplo 1.10**

Supongamos que  $X_t \in L^1$ ,  $X_t \in L^1$  y  $|X_t| \leq |Y_t|$  para todo  $t \in T$ . Si el conjunto  $\{Y_t\}$  es u.i. entonces  $\{X_t\}$  también lo es. Esto sigue fácilmente de la definición.

### 1.6.1. Convergencia de Momentos

**Lema 1.3**

$$X_n \xrightarrow{L^1} X \Leftrightarrow \sup_{A \in \mathcal{F}} \left| \int_A X_n dP - \int_A X dP \right| \rightarrow 0.$$

**Demostración.** Si  $X_n \xrightarrow{L^1} X$  entonces

$$\begin{aligned} \sup_A \left| \int_A X_n dP - \int_A X dP \right| &= \sup_A \left| \int_A (X_n - X) dP \right| \leq \sup_A \int_A |X_n - X| dP \\ &\leq \int |X_n - X| dP = \mathbb{E}(|X_n - X|) \rightarrow 0. \end{aligned}$$

Veamos ahora el recíproco, tenemos

$$\begin{aligned} \mathbb{E}|X_n - X| &= \int_{\{X_n > X\}} (X_n - X) dP + \int_{\{X_n \leq X\}} (X - X_n) dP \\ &= \int_{\{X_n > X\}} X_n dP - \int_{\{X_n > X\}} X dP + \int_{\{X_n \leq X\}} X dP - \int_{\{X_n \leq X\}} X_n dP \\ &\leq 2 \sup_A \left| \int_A X_n dP - \int_A X dP \right|. \end{aligned}$$
■

**Lema 1.4** Si  $X_n \xrightarrow{L^p} X$  para  $p \geq 1$  entonces  $\mathbb{E}(|X_n|^p) \rightarrow \mathbb{E}(|X|^p)$  o equivalentemente  $\|X_n\|_p \rightarrow \|X\|_p$ .

**Demostración.**  $X = X_n + X - X_n$ . Por la desigualdad de Minkowski

$$\|X\|_p \leq \|X_n\|_p + \|X - X_n\|_p.$$

De manera similar

$$\|X_n\|_p \leq \|X\|_p + \|X - X_n\|_p.$$

Combinando obtenemos

$$|\|X_n\|_p - \|X\|_p| \leq \|X - X_n\|_p \rightarrow 0. \quad (1.11)$$

■

**Teorema 1.17** *Supongamos que  $X_n \in L^1$  para  $n \geq 1$ . Las siguientes afirmaciones son equivalentes*

- $\{X_n\}$  converge en  $L^1$ .
- $\{X_n\}$  es de Cauchy en  $L^1$ :  $E|X_n - X_m| \rightarrow 0$  cuando  $n, m \rightarrow \infty$ .
- $\{X_n\}$  es u.i. y converge en probabilidad.

**Demostración.** (a)  $\Rightarrow$  (b) por la desigualdad triangular.

(b)  $\Rightarrow$  (c) Veamos primero que  $\{X_n\}$  es u.i. Dado  $\varepsilon > 0$  existe  $N_\varepsilon$  tal que si  $m, n \geq N_\varepsilon$  entonces

$$\int |X_n - X_m| dP < \frac{\varepsilon}{2}.$$

Para ver que  $\{X_n\}$  es u.i. usaremos la caracterización del teorema 1.13. Para cualquier  $A \in \mathcal{F}$ ,

$$\int_A |X_n| dP \leq \int_A |X_n - X_{N_\varepsilon} + X_{N_\varepsilon}| dP \leq \int_A |X_{N_\varepsilon}| dP + \int_A |X_n - X_{N_\varepsilon}| dP.$$

Si  $n \geq N_\varepsilon$ ,

$$\int_A |X_n| dP \leq \int_A |X_{N_\varepsilon}| dP + \frac{\varepsilon}{2}$$

de modo que

$$\sup_{n \geq N_\varepsilon} \int_A |X_n| dP \leq \int_A |X_{N_\varepsilon}| dP + \frac{\varepsilon}{2}$$

lo que implica que

$$\sup_n \int_A |X_n| dP \leq \sup_{m \leq N_\varepsilon} \int_A |X_m| dP + \frac{\varepsilon}{2}$$

Si  $A = \Omega$  concluimos que

$$\sup_n E|X_n| \leq \sup_{m \leq N_\varepsilon} E|X_m| + \frac{\varepsilon}{2} < \infty.$$

Además, como familias finitas de variables en  $L^1$  son u.i.,  $\{X_m, m \leq N_\varepsilon\}$  es u.i. y dado  $\varepsilon > 0$  existe  $\delta$  tal que si  $P(A) < \delta$ ,

$$\sup_{m \leq N_\varepsilon} \int_A |X_m| dP < \frac{\varepsilon}{2},$$

de modo que si  $P(A) < \delta$  tenemos que

$$\sup_n \int_A |X_n| dP \leq \varepsilon.$$

Falta ver que  $(X_n)$  converge en probabilidad. Tenemos

$$P(|X_n - X_m| > \varepsilon) \leq \frac{1}{\varepsilon} E(|X_n - X_m|) \rightarrow 0$$

cuando  $n, m \rightarrow \infty$ . Por lo tanto  $(X_n)$  es de Cauchy en probabilidad y por lo tanto converge en probabilidad.

(c)  $\Rightarrow$  (a) Si  $X_n \rightarrow X$  en probabilidad, existe una subsucesión  $X_{n_k}$  tal que  $X_{n_k} \rightarrow X$  c.s.. Por el lema de Fatou

$$\begin{aligned} \mathbb{E}(|X|) &= \mathbb{E}(\liminf |X_{n_k}|) \leq \liminf \mathbb{E}(|X_{n_k}|) \\ &\leq \sup_n \mathbb{E}(|X_n|) < \infty \end{aligned}$$

ya que  $(X_n)$  es u.i.. Por lo tanto  $X \in L^1$ .

Dado  $\varepsilon > 0$  tenemos

$$\begin{aligned} \int |X_n - X| dP &\leq \int_{\{|X_n - X| \leq \varepsilon\}} |X_n - X| dP + \int_{\{|X_n - X| > \varepsilon\}} |X_n| dP + \int_{\{|X_n - X| > \varepsilon\}} |X| dP \\ &\leq \varepsilon + T_1 + T_2 \end{aligned}$$

Como  $X_n \xrightarrow{P} X$ ,  $P(|X_n - X| > \varepsilon) \rightarrow 0$  y por lo tanto  $T_2 \rightarrow 0$  cuando  $n \rightarrow \infty$ . Para ver que  $T_1 \rightarrow 0$ , como  $(X_n)$  es u.i., dado  $\varepsilon > 0$  existe  $\delta$  tal que si  $P(A) < \delta$ ,

$$\sup_{n \geq 1} \int_A |X_n| dP < \varepsilon$$

Basta escoger  $n$  grande de modo que  $P(|X_n - X| > \varepsilon) < \delta$  y se tiene que  $T_1 < \varepsilon$ . ■

## 1.7. El Lema de Scheffé

Hemos visto en secciones anterior la relación entre convergencia de momentos y distintos tipos de convergencia. La pregunta que nos hacemos ahora es cual es la relación entre convergencia débil y convergencia de densidades.

### Ejemplo 1.11

Sea  $X_n$ ,  $n \geq 1$  una sucesión de v.a. con densidades

$$f_{X_n}(x) = \begin{cases} 1 - \cos(2\pi nx), & \text{para } 0 \leq x \leq 1, \\ 0, & \text{en otro caso.} \end{cases}$$

Entonces

$$F_{X_n}(x) = \begin{cases} 0, & \text{para } x \leq 0, \\ x - \frac{\sin(2\pi nx)}{2\pi n} \rightarrow x, & \text{para } 0 \leq x \leq 1, \\ 1, & \text{para } x \geq 1. \end{cases}$$

lo cual implica que  $X_n \xrightarrow{d} \mathcal{U}(0, 1)$  cuando  $n \rightarrow \infty$ . Sin embargo, las densidades oscilan y por lo tanto no pueden converger.

**Definición 1.10** La *distancia en variación total* entre las f.d.  $F$  y  $G$  se define como

$$d(F, G) = \sup_{A \in \mathcal{B}} |F(A) - G(A)|.$$

Si las variables  $X$  e  $Y$  tienen f.d.  $F$  y  $G$  respectivamente, la definición es equivalente a

$$d(X, Y) = \sup_{A \in \mathcal{B}} |P(X \in A) - P(Y \in A)|.$$

Si  $X$  y  $X_n$ ,  $n \geq 1$  son v.a. tales que

$$d(X_n, X) \rightarrow 0 \quad (n \rightarrow \infty),$$

decimos que  $X_n$  converge a  $X$  en variación total cuando  $n \rightarrow \infty$ .

Como los conjuntos  $(-\infty, x]$  son de Borel para todo  $x$ , tenemos que

$$|P(X_n \leq x) - P(X \leq x)| \leq \sup_{A \in \mathcal{B}} |P(X_n \in A) - P(X \in A)|,$$

lo cual implica el siguiente resultado.

**Lema 1.5** Sea  $\{X_n, n \geq 1\}$  una sucesión de v.a. Si  $X_n \rightarrow X$  en variación total cuando  $n \rightarrow \infty$  entonces  $X_n \xrightarrow{d} X$  cuando  $n \rightarrow \infty$ .

**Teorema 1.18 (Lema de Scheffé)** Supongamos que  $X$  y  $X_n$ ,  $n \geq 1$  son v.a. absolutamente continuas. Entonces

$$\sup_{A \in \mathcal{B}} |P(X_n \in A) - P(X \in A)| \leq \int_{\mathbb{R}} |f_{X_n}(x) - f_X(x)| dx, \quad (1.12)$$

y si  $f_{X_n}(x) \rightarrow f_X(x)$  c.s. cuando  $n \rightarrow \infty$ , entonces  $d(X_n, X) \rightarrow 0$  cuando  $n \rightarrow \infty$ . En particular,  $X_n \xrightarrow{d} X$  cuando  $n \rightarrow \infty$ .

**Demostración.** Sea  $A \in \mathcal{B}$ , tenemos

$$\begin{aligned} |P(X_n \in A) - P(X \in A)| &= \left| \int_A f_{X_n}(x) - \int_A f_X(x) dx \right| \\ &\leq \int_A |f_{X_n}(x) - f_X(x)| dx \\ &\leq \int_{\mathbb{R}} |f_{X_n}(x) - f_X(x)| dx, \end{aligned}$$

lo cual demuestra (1.12).

Para demostrar la convergencia observamos que

$$\int_{\mathbb{R}} (f_{X_n}(x) - f_X(x)) dx = 1 - 1 = 0,$$

de modo que

$$\int_{\mathbb{R}} (f_{X_n}(x) - f_X(x))^+ dx = \int_{\mathbb{R}} (f_{X_n}(x) - f_X(x))^- dx.$$

Además,  $(f_X(x) - f_{X_n}(x))^+ \rightarrow 0$  c.s. cuando  $n \rightarrow \infty$ , y  $0 \leq (f_X(x) - f_{X_n}(x))^+ \leq f_X(x)$ , y usando el teorema de convergencia dominada

$$\int_{\mathbb{R}} |f_X(x) - f_{X_n}(x)| dx = 2 \int_{\mathbb{R}} (f_X(x) - f_{X_n}(x))^+ dx \rightarrow 0 \quad (n \rightarrow \infty).$$

Esto demuestra la convergencia en variación total. ■

**Observación 1.6** Es posible demostrar que

$$d(X_n, X) = \frac{1}{2} \int_{\mathbb{R}} |f_{X_n}(x) - f_X(x)| dx.$$

## 1.8. Convergencia Vaga

En nuestra definición de convergencia en distribución hemos supuesto que la función de distribución límite  $F$  es propia, es decir que  $F(\mathbb{R}) = 1$  pero este no es siempre el caso. Esta es la distinción fundamental entre la convergencia en distribución y un nuevo tipo de convergencia que definiremos a continuación.

**Definición 1.11** Una sucesión  $\{F_n, n \geq 1\}$  de f.d converge vagamente a la f.d (posiblemente impropia)  $H$  si, para todo intervalo finito  $I = (a, b]$  con  $a, b \in \mathcal{C}(H)$ ,

$$F_n(I) \rightarrow H(I) \quad (n \rightarrow \infty)$$

Notación:  $F \xrightarrow{v} H$  cuando  $n \rightarrow \infty$ .

### Ejemplo 1.12

Sea  $P(X_n = n) = P(X_n = -n) = 1/2$ , entonces

$$F_n(x) = \begin{cases} 0, & \text{para } x < -n, \\ \frac{1}{2}, & \text{para } -n \leq x < n, \\ 1, & \text{para } x \geq n. \end{cases}$$

De modo que para todo  $x \in \mathbb{R}$

$$F_n(x) \rightarrow H(x) = \frac{1}{2} \quad (n \rightarrow \infty).$$

$H$  tiene todas las propiedades de una función de distribución salvo que  $F(\mathbb{R}) = 0$ .

### Ejemplo 1.13

Sea  $X_n \sim \mathcal{U}(-n, n)$ ,  $n \geq 1$ . La función de distribución es

$$F_{X_n}(x) = \begin{cases} 0, & \text{para } x < -n, \\ \frac{x+n}{2n}, & \text{para } -n \leq x < n, \\ 1, & \text{para } x \geq n. \end{cases}$$

De nuevo, esta sucesión converge cuando  $n \rightarrow \infty$  a  $H(x) = 1/2$  para todo  $x \in \mathbb{R}$ .

Si  $X_n \xrightarrow{d} X$  cuando  $n \rightarrow \infty$  entonces, por definición,  $F_{X_n}(x) \rightarrow F_X(x)$  cuando  $n \rightarrow \infty$  para  $x \in \mathcal{C}(F_X)$ , de donde se obtiene de inmediato que para cualquier intervalo  $I = (a, b]$  acotado tal que  $a, b \in \mathcal{C}(F_X)$ ,

$$F_{X_n}(I) = F_{X_n}(b) - F_{X_n}(a) \rightarrow F_X(b) - F_X(a) = F_X(I)$$

cuando  $n \rightarrow \infty$ , de modo que convergencia en distribución siempre implica convergencia vaga.

**Teorema 1.19 (Principio de Selección de Helly)** Sea  $\{F_n, n \geq 1\}$  una sucesión de f.d. Entonces existe una subsucesión no-decreciente  $\{n_k, k \geq 1\}$  tal que

$$F_{n_k} \xrightarrow{v} H \quad \text{cuando } k \rightarrow \infty,$$

para alguna función de distribución  $H$ , posiblemente impropia.

**Demostración.** La demostración usa el método diagonal. Sea  $\{r_k, k \geq 1\}$  una enumeración de los racionales. Como la sucesión  $(F_n(r_1))_{n \geq 1}$  está acotada, por el teorema de Bolzano-Weierstrass existe un punto de acumulación  $j_1$  y una subsucesión  $\{F_{1,k}(r_1), k \geq 1\}$  tal que

$$F_{1,k}(r_1) \rightarrow j_1 \quad \text{cuando } k \rightarrow \infty,$$

donde  $0 \leq j_1 \leq 1$ . El mismo argumento aplicado a la subsucesión  $\{F_{2,k}(r_2)\}$  produce un punto de acumulación  $j_2$  y una subsucesión  $\{F_{2,k}(r_2), k \geq 1\}$  tal que

$$F_{2,k}(r_2) \rightarrow j_2 \quad \text{cuando } k \rightarrow \infty,$$

donde  $0 \leq j_2 \leq 1$ . Además, esta subsucesión converge también para  $r_1$ , ya que es una subsucesión de la primera subsucesión. Continuando este procedimiento obtenemos, cuando  $k \rightarrow \infty$ ,

$$\begin{aligned} F_{1,k}(r_1) &\rightarrow j_1, \\ F_{2,k}(r_i) &\rightarrow j_i, \quad \text{para } i = 1, 2, \\ F_{3,k}(r_i) &\rightarrow j_i, \quad \text{para } i = 1, 2, 3 \\ &\vdots \quad \quad \quad \vdots \\ F_{m,k}(r_i) &\rightarrow j_i, \quad \text{para } i = 1, 2, \dots, m \\ &\vdots \quad \quad \quad \vdots \end{aligned}$$

Ahora consideramos la diagonal de este arreglo,  $\{F_{k,k}, k \geq 1\}$  que, salvo por un número finito de términos al comienzo, es una subsucesión de todas las subsucesiones horizontales, y por lo tanto converge en todo  $\mathbb{Q}$ . Tenemos, por lo tanto, un conjunto denso numerable en el cual la sucesión converge.

Definimos ahora la función  $H$ : Ponemos

$$H(r_i) = j_i, \quad \text{para } r_i \in \mathbb{Q}.$$

Como  $0 \leq j_i \leq 1$  para todo  $i$  tenemos que  $0 \leq H(r_i) \leq 1$  para  $r_i \in \mathbb{Q}$ . Además, si  $r < s$ ,  $r, s \in \mathbb{Q}$ , entonces

$$0 \leq F_{k,k}(s) - F_{k,k}(r) \rightarrow H(s) - H(r)$$

cuando  $k \rightarrow \infty$ , lo cual muestra que  $H$  es no-decreciente en  $\mathbb{Q}$ .

Sea ahora  $x \in \mathbb{R}$  arbitrario y escogemos  $r, s \in \mathbb{Q}$  tal que  $r < x < s$ . Como  $F_{k,k}(r) \leq F_{k,k}(x) \leq F_{k,k}(s)$ , tomando límites obtenemos que

$$H(r) \leq \liminf_{k \rightarrow \infty} F_{k,k}(x) \leq \limsup_{k \rightarrow \infty} F_{k,k}(x) \leq H(s),$$

y como podemos escoger  $r$  y  $s$  tan cerca como queramos de  $x$ ,

$$H(x^-) \leq \liminf_{k \rightarrow \infty} F_{k,k}(x) \leq \limsup_{k \rightarrow \infty} F_{k,k}(x) \leq H(x^+)$$

Esto prueba que siempre existe una subsucesión que converge a una función no-decreciente  $H$  que toma valores en  $[0, 1]$  en sus puntos de continuidad. Para que  $H$  sea continua por la derecha, completamos su definición poniendo

$$H(x) = \lim_{r_i \downarrow x} H(r_i) \quad \text{para } x \in \mathbb{R},$$

es decir, escogemos la versión de  $H$  que es continua por la derecha. ■

**Observación 1.7** Es necesario notar que el teorema de Helly no dice que  $F_{k,k}(\infty) \rightarrow H(\infty)$ .

Si llamamos  $\mathcal{M}$  a la clase de las funciones de distribución posiblemente degeneradas, es decir, a las funciones  $H : \mathbb{R} \rightarrow \mathbb{R}$  que son no-decrecientes, continuas por la derecha y satisfacen  $G(-\infty) \geq 0$ ,  $G(\infty) \leq 1$ , entonces el teorema de Helly dice que  $\mathcal{M}$  es *relativamente o secuencialmente compacto*. Ya hemos visto en los ejemplos 1.12 y 1.13 que la clase de las funciones de distribución no es compacta.

**Corolario 1.6** Sea  $F_n$  una sucesión en  $\mathcal{M}$ . Si existe  $H \in \mathcal{M}$  tal que para toda subsucesión vagamente convergente  $(F_{n_k})$  se tiene que  $F_{n_k} \xrightarrow{v} H$ , entonces la sucesión también converge vagamente a  $H$ :  $F_n \xrightarrow{v} H$ .

**Demostración.** Supongamos que  $F_n$  no converge vagamente a  $H$ , entonces existe  $x_0 \in \mathcal{C}(H)$  tal que  $F_n(x_0) \not\rightarrow H(x_0)$ . Pero toda subsucesión de las  $F_n$  tiene una subsucesión convergente  $F_{n_k}$  y  $F_{n_k}(x_0) \rightarrow H(x_0)$ . Esto implica que  $F_n(x_0) \rightarrow H(x_0)$ , lo cual es una contradicción. ■

**Observación 1.8** Denotamos por  $\mathcal{C}_0(\mathbb{R})$  a la clase de funciones reales continuas tales que  $|h(x)| \rightarrow 0$  cuando  $x \rightarrow \pm\infty$ . Llamamos  $\mathcal{C}_K(\mathbb{R})$  a la clase de funciones continuas a soporte compacto ( $f \in \mathcal{C}_K$  si existe un conjunto compacto  $K(f)$  tal que  $f$  se anula fuera de  $K(f)$ ). Finalmente, llamamos  $\mathcal{C}_B(\mathbb{R})$  a las funciones continuas y acotadas. Tenemos

$$\mathcal{C}_K \subset \mathcal{C}_0 \subset \mathcal{C}_B \subset \mathcal{C}.$$

Hemos visto en el teorema 1.10 que las integrales de funciones en  $\mathcal{C}_B$  caracterizan la convergencia en distribución:  $F_n \xrightarrow{d} F$  si y sólo si  $\int f dF_n \rightarrow \int f dF$  para toda  $f \in \mathcal{C}_B(\mathbb{R})$ . El siguiente teorema nos da una caracterización similar para la convergencia vaga. Primero unas definiciones y un lema de aproximación.

Una función cualquiera en un espacio arbitrario tiene *soporte* en un subconjunto  $S$  del espacio si  $f$  se anula fuera del conjunto  $S$ . Por lo tanto, si  $f \in \mathcal{C}_K(\mathbb{R})$ ,  $f$  tiene soporte en algún conjunto compacto y por lo tanto también en un intervalo compacto. Una *función escalera* en el intervalo (finito o infinito)  $(a, b)$  es una función con soporte en este intervalo tal que para alguna partición finita  $a = a_1 < \dots < a_k = b$  se tiene que  $f(x) = c_j$  para  $x \in (a_j, a_{j+1})$  y  $1 \leq j \leq k$ , donde los  $c_j$  son números reales. Decimos que la función es a valores en  $D$  si  $a_j \in D$ ,  $c_j \in D$  para  $1 \leq j \leq k$ . Observamos que hemos dejado sin especificar los valores de la función  $f$  en los puntos de la partición para tener flexibilidad.

**Lema 1.6 (de Aproximación)** Supongamos que  $f \in \mathcal{C}_K(\mathbb{R})$  tiene soporte en el intervalo compacto  $[a, b]$ . Dado cualquier conjunto denso  $A$  de  $\mathbb{R}$  y  $\varepsilon > 0$  existe una función escalera en  $(a, b)$  definida usando una partición con valores en  $A$  tal que

$$\sup_{s \in \mathbb{R}} |f(x) - f_\varepsilon(x)| \leq \varepsilon. \quad (1.13)$$

**Demostración.** Este lema es un caso particular del teorema de Stone-Weierstrass. ■

**Teorema 1.20** Sea  $\{H_n, n \geq 1\}$  una sucesión de funciones en  $\mathcal{M}$ . Entonces  $H_n \xrightarrow{v} H$  si y sólo si para toda  $f \in \mathcal{C}_K$ ,

$$\int_{\mathbb{R}} f dH_n \rightarrow \int f dH. \quad (1.14)$$

**Demostración.** Supongamos que  $H_n \xrightarrow{d} H$ . (1.14) es cierta si  $f$  es la función indicadora de  $(a, b]$  para  $a, b \in D$  donde  $D$  es un subconjunto denso de  $\mathcal{C}(H)$ . Por la linealidad de las integrales también es cierto si  $f$  es una función escalera definida a partir de una partición con valores en  $D$ . Si  $f \in \mathcal{C}_K$  y  $\varepsilon > 0$ , por el lema de aproximación existe una función escalera  $f_\varepsilon$  que satisface (1.13). Tenemos

$$\left| \int f dH_n - \int f dH \right| \leq \left| \int (f - f_\varepsilon) dH_n \right| + \left| \int f_\varepsilon dH_n - \int f_\varepsilon dH \right| + \left| \int (f_\varepsilon - f) dG \right|. \quad (1.15)$$

El primer término del lado derecho está acotado por

$$\int |f - f_\varepsilon| dH_n \leq \varepsilon \int dH_n \leq \varepsilon,$$

y una acotación similar sirve para el tercer término. El segundo término tiende a cero porque  $f_\varepsilon$  es una función escalera a valores en  $D$ . Por lo tanto el lado derecho de (1.15) está acotado por  $2\varepsilon$  cuando  $n \rightarrow \infty$  y por lo tanto converge a 0.

Para demostrar el recíproco basta observar que las funciones  $g_k$  y  $h_k$  que definimos para la demostración del teorema 1.10 son funciones continuas a soporte compacto y por lo tanto el mismo argumento demuestra la convergencia

$$H_n(a, b] \rightarrow H(a, b] \quad (n \rightarrow \infty)$$

para  $a, b \in \mathcal{C}(H)$ . ■

### 1.8.1. Convergencia Vaga y Tensión.

Ahora consideraremos la relación entre convergencia vaga y convergencia en distribución.

**Teorema 1.21 (Prohorov)** *Sea  $\{F_n, n \geq 1\}$  una sucesión de f.d. Para que toda subsucesión que converge vagamente converja en distribución es necesario y suficiente que*

$$\int_{|x|>a} dF_n(x) \rightarrow 0 \quad \text{cuando } a \rightarrow \infty \quad (1.16)$$

*uniformemente en  $n$ .*

#### **Demostración.**

Supongamos que  $F_{n_k} \xrightarrow{v} H$  para alguna  $H \in \mathcal{M}$  cuando  $k \rightarrow \infty$  y que (1.16) vale. Como la masa total de  $H$  es finita tenemos, para cualquier  $\varepsilon > 0$ , existe  $a_H$  tal que

$$\int_{|x|>a} dH(x) < \varepsilon \quad \text{para } a > a_H.$$

Además, por hipótesis tenemos que

$$\sup_n \int_{|x|>a} dF_n(x) < \varepsilon \quad \text{para } a > a_0.$$

Entonces, para  $a > \max\{a_h, a_0\}$ , tenemos que para todo  $k$ ,

$$\begin{aligned} 1 - \int_{-\infty}^{\infty} dH(x) &= \int_{-\infty}^{\infty} dF_{n_k}(x) - \int_{-\infty}^{\infty} dH(x) \\ &\leq \int_{|x|>a} dF_{n_k}(x) + \left| \int_{-a}^a dF_{n_k}(x) - \int_{-a}^a dH(x) \right| + \int_{|x|>a} dH(x) \\ &\leq \varepsilon + \left| \int_{-a}^a dF_{n_k}(x) - \int_{-a}^a dH(x) \right| + \varepsilon \end{aligned}$$

de modo que, por el teorema 1.20,

$$1 - \int_{-\infty}^{\infty} dH(x) < 2\varepsilon,$$

lo cual implica que la masa total de  $H$  es 1.

Veamos ahora la demostración de la necesidad. Sabemos que  $F_n \xrightarrow{d} H$  cuando  $n \rightarrow \infty$ , de modo que  $H$  es propia, y queremos verificar que (1.16) vale. Supongamos lo contrario, entonces, dado  $\varepsilon > 0$  existen sucesiones crecientes y no acotadas  $\{n_k, k \geq 1\}$  y  $\{a_k, k \geq 1\}$  tales que

$$\int_{|x|>a_k} dF_{n_k}(x) > 2\varepsilon.$$

Por otro lado, como antes,

$$\int_{|x|>a} dH(x) < \varepsilon \quad \text{para } a > a_H,$$

Además, como sólo estamos considerando una cantidad numerable de distribuciones y una f.d. tiene, a lo sumo, una cantidad numerable de discontinuidades, podemos suponer sin restricción que  $a$  y  $(a_k)_{k \geq 1}$  son puntos de continuidad de todas las distribuciones que consideramos.

Dado cualquier  $a > a_H$  existe un  $k_0$  tal que  $a_k > a$  para  $k > k_0$ . Sean  $a$  y  $k > k_0$  dados, combinando los resultados anteriores obtenemos

$$\begin{aligned} 1 - \int_{-\infty}^{\infty} dH(x) &= \int_{-\infty}^{\infty} dF_{n_k}(x) - \int_{-\infty}^{\infty} dH(x) \\ &= \int_{|x|>a} dF_{n_k}(x) - \int_{|x|>a} dH(x) + \left( \int_{-a}^a dF_{n_k}(x) - \int_{-a}^a dH(x) \right) \\ &> 2\varepsilon - \varepsilon + \left( \int_{-a}^a dF_{n_k}(x) - \int_{-a}^a dH(x) \right) \end{aligned}$$

y por el teorema 1.20,

$$1 - \int_{-\infty}^{\infty} dH(x) > \varepsilon,$$

de modo que  $H$  no es propia. Esta contradicción concluye la demostración del teorema.  $\blacksquare$

Una sucesión de distribuciones que satisface (1.16) no permite que la masa escape a infinito por la uniformidad de la condición en  $n$ : Todas las distribuciones tienen masas uniformemente pequeñas fuera de intervalos suficientemente grandes. Decimos que una sucesión de distribuciones que satisfacen esta propiedad es *tensa*. Si  $\{X_n, n \geq 1\}$  es una sucesión de v.a. cuyas distribuciones asociadas forman una sucesión tensa decimos que la sucesión  $\{X_n, n \geq 1\}$  es *tensa*.

El teorema de Prohorov dice que una familia de f.d. es tensa si y sólo si es relativamente compacta. Combinando el teorema de Prohorov y el corolario 1.6 obtenemos el siguiente resultado.

**Corolario 1.7** *Sea  $\{F_n, n \geq 1\}$  una sucesión tensa de f.d. Si todas las subsucesiones convergentes de  $F_n$  convergen al mismo límite  $F$ , entonces  $F_n \xrightarrow{d} F$ .*

Observamos que para cualquier  $p > 0$

$$P(|X_n| > a) \leq \frac{1}{a^p} \mathbb{E} |X_n|^p \mathbf{1}_{\{|X|>a\}} \leq \frac{1}{a^p} \sup_n \mathbb{E} |X_n|^p,$$

de donde obtenemos la primera parte del siguiente corolario.

**Corolario 1.8** (i) *Sea  $p > 0$ . Una sucesión acotada en  $L^p$  es tensa. En particular, sucesiones uniformemente integrables son tensas.*

(ii) *Sea  $g \uparrow \infty$  una función no negativa y supongamos que  $\sup_n \mathbb{E} g(X_n) < \infty$ . Entonces  $\{X_n, n \geq 1\}$  es tensa.*

Usando el teorema 1.21 podemos demostrar el siguiente resultado.

**Teorema 1.22** *Sea  $\{X_n, n \geq 1\}$  una sucesión tensa. Entonces  $X_n \xrightarrow{d} X$  cuando  $n \rightarrow \infty$  si y sólo si toda subsucesión contiene una subsucesión que converge vagamente a  $X$ .*

### 1.8.2. Clases Separantes de Funciones

**Definición 1.12** Una clase  $\mathcal{E}$  de funciones continuas y acotadas en  $\mathbb{R}$  es *separante* si para cualquier par  $F, G$  de f.d. se tiene que

$$\int f dF = \int f dG, \quad \forall f \in \mathcal{E} \quad \Rightarrow \quad F = G.$$

**Proposición 1.7** Sea  $\mathcal{E}$  una clase separante y  $\{F_n, n \geq 1\}$  una sucesión tensa de f.d. Entonces existe una f.d.  $F$  tal que  $F_n \xrightarrow{d} F$  si y sólo si

$$\lim_n \int f dF_n \text{ existe para toda } f \in \mathcal{E}.$$

Si esto es cierto, entonces  $\lim_n \int f dF_n = \int f dF$ , para toda  $f \in \mathcal{E}$ .

**Demostración.** Si  $F_n \xrightarrow{d} F$  entonces  $\lim_n \int f dF_n = \int f dF$  porque las funciones en  $\mathcal{E}$  son continuas y acotadas. Para ver el recíproco sea  $F_{n_k}$  una subsucesión convergente. Por la tensión  $F_{n_k} \xrightarrow{d} F$  donde  $F$  es una f.d. propia. Si tomamos cualquier otra subsucesión débilmente convergente  $F_{n'_k} \xrightarrow{d} G$ , para  $f \in \mathcal{E}$  se tiene que

$$\lim_k \int f dF_{n_k} = \int f dF, \quad \lim_k \int f dF_{n'_k} = \int f dG,$$

de modo que  $\int f dF = \int f dG$  para toda  $f \in \mathcal{E}$ . Esto implica que  $F = G$  y en consecuencia todas las subsucesiones convergentes de  $F_n$  tienen el mismo límite  $F$ . Por el corolario 1.7 tenemos  $F_n \xrightarrow{d} F$ . ■

**Corolario 1.9** Sea  $\mathcal{E}$  una clase separante y  $\{F_n, n \geq 1\}$  una colección tensa de f.d. Si  $F$  es una f.d. tal que  $\int f dF_n \rightarrow \int f dF$  para toda  $f \in \mathcal{E}$ , entonces  $F_n \xrightarrow{d} F$ .

## 1.9. El Teorema de Skorohod

Sabemos que convergencia casi segura implica convergencia débil y que el recíproco es falso. Sin embargo, el teorema de Skorohod nos da un recíproco parcial.

**Teorema 1.23 (Skorohod)** Sea  $\{X_n, n \geq 0\}$  una sucesión de v.a. definidas en un espacio de probabilidad  $(\Omega, \mathcal{F}, P)$  tales que  $X_n \xrightarrow{d} X_0$ . Entonces existen v.a.  $\{Y_n, n \geq 0\}$  definidas en el espacio de Lebesgue  $([0, 1], \mathcal{B}[0, 1], m)$  tales que para cada  $n \geq 0$  fijo,  $X_n \stackrel{d}{=} Y_n$  y  $Y_n \xrightarrow{c.s.} Y_0$  donde la convergencia casi segura es respecto a la medida de Lebesgue.

Para la demostración del teorema necesitamos el siguiente resultado

**Lema 1.7** Sea  $F_n$  la f.d. de  $X_n$ , de modo que  $F_n \xrightarrow{d} F_0$ . Si  $t \in (0, 1) \cap \mathcal{C}(F_0^-)$ , entonces  $F_n^{\leftarrow}(t) \rightarrow F_0^{\leftarrow}(t)$ .

**Demostración.** Como  $\mathcal{C}(F_0)^c$  es a lo sumo numerable, dado  $\varepsilon > 0$  existe  $x \in \mathcal{C}(F_0)$  tal que

$$F_0^{\leftarrow}(t) - \varepsilon < x < F_0^{\leftarrow}(t).$$

A partir de la definición de la función inversa,  $x < F_0^{\leftarrow}(t)$  implica que  $F_0(x) < t$ . Además,  $x \in \mathcal{C}(F_0)$  implica  $F_n(x) \rightarrow F_0(x)$ , de modo que para  $n$  grande tenemos  $F_n(t) < t$ . De nuevo, usando la definición de la función inversa, tenemos  $x \leq F_n^{\leftarrow}(t)$ . Por lo tanto,

$$F_0^{\leftarrow}(t) - \varepsilon < x \leq F_n^{\leftarrow}(t).$$

para todo  $n$  grande, y como  $\varepsilon > 0$  es arbitrario, obtenemos que

$$F_0^{\leftarrow}(t) \leq \liminf_{n \rightarrow \infty} F_n^{\leftarrow}(t). \quad (1.17)$$

Para cualquier  $t' > t$  podemos hallar  $y \in \mathcal{C}(F_0)$  tal que

$$F_0^{\leftarrow}(t') < y < F_0^{\leftarrow}(t') + \varepsilon.$$

y esto implica  $F_0(y) \geq t' > t$ . Como  $y \in \mathcal{C}(F_0)$ ,  $F_n(y) \rightarrow F_0(y)$  y para  $n$  grande,  $F_n(y) \geq t$ , de modo que  $y \geq F_n^{\leftarrow}(t)$  y en consecuencia

$$F_n^{\leftarrow}(t) \leq y < F_0^{\leftarrow}(t') + \varepsilon.$$

para todo  $n$  grande. Como  $\varepsilon > 0$  es arbitrario obtenemos

$$\limsup_{n \rightarrow \infty} F_n^{\leftarrow}(t) \leq F_0^{\leftarrow}(t').$$

Hacemos ahora  $t' \downarrow t$  y usamos la continuidad de  $F_0^{\leftarrow}$  en  $t$  para obtener

$$\limsup_{n \rightarrow \infty} F_n^{\leftarrow}(t) \leq F_0^{\leftarrow}(t). \quad (1.18)$$

Combinando (1.17) y (1.18) obtenemos el resultado. ■

**Demostración del teorema de Skorohod.** En el espacio  $[0, 1]$  definimos la variable aleatoria  $U(t) = t$  de modo que  $U$  tiene distribución uniforme, ya que para  $0 \leq x \leq 1$

$$m(U \leq x) = m(t \in [0, 1] : U(t) \leq x) = m([0, x]) = x.$$

Para  $n \geq 0$  definimos  $Y_n$  en  $[0, 1]$  por  $Y_n = F_n^{\leftarrow}(U)$ . Entonces para  $y \in \mathbb{R}$ ,

$$m(Y_n \leq y) = m(t \in [0, 1] : F_n^{\leftarrow}(t) \leq y) = m(t \in [0, 1] : t \leq F_n(y)) = F_n(y),$$

y concluimos que  $Y_n \stackrel{d}{=} X_n$  para todo  $n \geq 0$ . Ahora escribimos

$$m(t \in [0, 1] : Y_n(t) \rightarrow Y_0(t)) = m(t \in [0, 1] : F_n^{\leftarrow}(t) \rightarrow F_0^{\leftarrow}(t)),$$

y usando el lema 1.7, esto está acotado por

$$m(t \in [0, 1] : F_0^{\leftarrow} \text{ no es continua en } t) = 0$$

porque el conjunto de discontinuidades es numerable. ■

### 1.9.1. El Método Delta

Supongamos que tenemos una familia de modelos  $\{(\Omega, \mathcal{F}, P_\theta), \theta \in \Theta\}$ , y queremos estimar el parámetro  $\theta$  con base en una muestra de tamaño  $n$  usando el estadístico  $T_n = T_n(X_1, \dots, X_n)$ . El estimador  $T_n$  es consistente si

$$T_n \xrightarrow{P_\theta} \theta,$$

para cada  $\theta$ . El estimador es consistente y asintóticamente normal (CAN) si para todo  $\theta \in \Theta$

$$\lim_{n \rightarrow \infty} P_\theta(\sigma_n(T_n - \theta) \leq x) = \mathcal{N}(x; 0, 1),$$

para alguna sucesión  $\sigma_n \rightarrow \infty$ .

Supongamos que tenemos un estimador CAN de  $\theta$  pero queremos estimar una función suave  $g(\theta)$ . Por ejemplo, en una familia de densidades exponenciales,  $\theta$  puede representar la media pero estamos interesados en la varianza  $\theta^2$ . Usando el método delta vemos que  $g(T_n)$  también es CAN para  $g(\theta)$ .

Ilustramos el método usando el TCL que demostraremos más adelante. Sea  $\{X_j, j \geq 1\}$  una sucesión i.i.d. con  $E(X_n) = \mu$  y  $\text{Var}(X_n) = \sigma^2$ . El TCL dice que

$$\frac{S_n - n\mu}{\sigma\sqrt{n}} \xrightarrow{d} \mathcal{N}(0, 1).$$

Equivalentemente, podemos expresar este resultado en términos de  $\bar{X}_n = \sum_1^n X_i/n$  como

$$\sqrt{n} \left( \frac{\bar{X}_n - \mu}{\sigma} \right) \xrightarrow{d} \mathcal{N}(0, 1),$$

de modo que  $\bar{X}$  es un estimador CAN de  $\mu$ . El método delta dice que si  $g(x)$  tiene derivada no nula  $g'(\mu)$  en  $\mu$  entonces

$$\sqrt{n} \left( \frac{g(\bar{X}_n) - g(\mu)}{\sigma g'(\mu)} \right) \xrightarrow{d} \mathcal{N}(0, 1). \quad (1.19)$$

Vemos que  $g(\bar{X})$  es CAN para  $g(\mu)$ .

**Observación 1.9** La demostración no depende de que la variable límite tenga distribución  $\mathcal{N}(0, 1)$ .

**Demostración de (1.19).** Por el teorema de Skorohod existen variables  $Z'_n$  y  $N'$  en el espacio de Lebesgue tales que

$$Z'_n \stackrel{d}{=} \sqrt{n} \left( \frac{\bar{X} - \mu}{\sigma} \right), \quad N' \sim \mathcal{N}(0, 1)$$

y

$$Z'_n \rightarrow N' \quad \text{c.s. (m).}$$

Definimos

$$\bar{X}'_n = \mu + \sigma Z'_n / \sqrt{n},$$

de modo que  $\bar{X}_n \stackrel{d}{=} \bar{X}'_n$ . Usando la definición de derivada

$$\begin{aligned} \sqrt{n} \left( \frac{g(\bar{X}_n) - g(\mu)}{\sigma g'(\mu)} \right) &\stackrel{d}{=} \sqrt{n} \left( \frac{g(\mu + \sigma Z'_n / \sqrt{n}) - g(\mu)}{\sigma g'(\mu)} \right) \\ &= \frac{g(\mu + \sigma Z'_n / \sqrt{n}) - g(\mu)}{\sigma Z'_n / \sqrt{n}} \frac{Z'_n}{g'(\mu)} \\ &\stackrel{\text{c.s.}}{\rightarrow} g'(\mu) \frac{N'}{g'(\mu)} = N' \sim \mathcal{N}(0, 1), \end{aligned}$$

ya que  $\sigma Z'_n / \sqrt{n} \rightarrow 0$  c.s. ■

## 1.10. Convergencia en Distribución II

**Teorema 1.24 (Slutsky)** Sean  $\{X, X_n, Y_n, \xi_n, n \geq 1\}$  variables aleatorias. Si  $X_n \xrightarrow{d} X$  y  $X_n - Y_n \xrightarrow{P} 0$  entonces  $Y_n \xrightarrow{d} X$ . Equivalentemente, si  $X_n \xrightarrow{d} X$  y  $\xi_n \xrightarrow{P} 0$  entonces  $X_n + \xi_n \xrightarrow{d} X$ .

**Demostración.** Basta probar la segunda afirmación. Sea  $f$  una función real, acotada y uniformemente continua. Definimos el módulo de continuidad por

$$\omega_\delta(f) = \sup_{|x-y| \leq \delta} |f(x) - f(y)|.$$

Como  $f$  es uniformemente continua tenemos que

$$\omega_\delta(f) \rightarrow 0, \quad \text{cuando } \delta \rightarrow 0. \quad (1.20)$$

Por el corolario 1.4 basta ver que  $E(f(X_n + \xi_n)) \rightarrow E(f(X))$ . Para esto observemos que

$$\begin{aligned} |E(f(X_n + \xi_n)) - E(f(X))| &\leq |E(f(X_n + \xi_n)) - E(f(X_n))| + |E(f(X_n)) - E(f(X))| \\ &\leq E(|f(X_n + \xi_n) - f(X_n)|\mathbf{1}_{\{|\xi_n| \leq \delta\}}) + 2 \sup_x |f(x)|P(|\xi_n| > \delta) + o(1) \\ &\leq \omega_\delta(f) + \text{Const } P(|\xi_n| > \delta) + o(1). \end{aligned}$$

Haciendo  $n \rightarrow \infty$  y luego  $\delta \rightarrow 0$  y usando (1.20) obtenemos el resultado.  $\blacksquare$

A continuación presentamos una generalización del teorema de Slutsky. La demostración de este resultado puede verse en el libro de Resnick.

**Teorema 1.25** Sean  $\{X_{un}, X_u, Y_n, X, n \geq 1\}$  variables aleatorias tales que para cada  $n$ ,  $Y_n, X_{un}, u \geq 1$  están definidas en un mismo espacio de probabilidad. Supongamos que para cada  $u$ , cuando  $n \rightarrow \infty$ ,  $X_{un} \xrightarrow{d} X_u$  y cuando  $u \rightarrow \infty$ ,  $X_u \xrightarrow{d} X$ . Supongamos además que para todo  $\varepsilon > 0$ ,

$$\lim_{u \rightarrow \infty} \limsup_{n \rightarrow \infty} P(|X_{un} - Y_n| > \varepsilon) = 0.$$

Entonces tenemos  $Y_n \xrightarrow{d} X$  cuando  $n \rightarrow \infty$ .

## 1.11. Teorema de Convergencia a Familias

Muchos resultados de convergencia de variables aleatorias son del siguiente tipo: Para una sucesión de v.a.  $\xi_n, n \geq 1$  y constantes  $a_n > 0$  y  $b_n \in \mathbb{R}$ , se demuestra que

$$\frac{\xi_n - b_n}{a_n} \xrightarrow{d} Y,$$

donde  $Y$  es una v. a. no-degenerada. Usando esto tenemos

$$P\left(\frac{\xi_n - b_n}{a_n} \leq x\right) \approx P(Y \leq x) = G(x),$$

o poniendo  $y = a_n x + b_n$ ,

$$P(\xi_n \leq y) \approx G\left(\frac{y - b_n}{a_n}\right).$$

Esto permite aproximar la distribución de  $\xi_n$  por una familia de distribuciones con parámetros de ubicación y escala.

La pregunta ahora es ¿Hasta qué punto son únicas estas constantes de normalización  $a_n$  y  $b_n$ ? La respuesta la da el teorema de convergencia a familias de distribuciones: Las constantes están determinadas salvo por equivalencias asintóticas y la distribución límite está determinada salvo por parámetros de ubicación y escala.

**Definición 1.13** Dos distribuciones  $F$  y  $G$  son del mismo tipo o pertenecen a la misma familia si para algunas constantes  $a > 0$ ,  $b \in \mathbb{R}$ ,

$$G(x) = F(ax + b), \quad x \in \mathbb{R}.$$

En términos de variables aleatorias, si  $X \sim F$  y  $Y \sim G$  entonces

$$Y \stackrel{d}{=} \frac{X - b}{a}.$$

Por ejemplo, podemos considerar la familia gaussiana. Si  $X_{\mu,\sigma}$  tiene distribución  $N(\mu, \sigma^2)$ , entonces  $X_{\mu,\sigma} \stackrel{d}{=} \sigma X_{0,1} + \mu$ .

**Teorema 1.26 (Convergencia a familias, Gnedenko & Khinchin)** Sean  $G(x)$  y  $H(x)$  dos funciones de distribución propias, ninguna de las cuales está concentrada en un punto. Supongamos que para  $n \geq 1$ ,  $X_n$  son v.a. con funciones de distribución  $F_n$  y  $U$  y  $V$  son v.a. con f.d.  $G$  y  $H$ , respectivamente. Sean, además, constantes  $a_n > 0$ ,  $\alpha_n > 0$ ,  $b_n \in \mathbb{R}$ ,  $\beta_n \in \mathbb{R}$ .

a) Si

$$F_n(a_n x + b_n) \rightarrow G(x), \quad F_n(\alpha_n x + \beta_n) \rightarrow H(x) \quad (1.21)$$

o equivalentemente

$$\frac{X_n - b_n}{a_n} \xrightarrow{d} U, \quad \frac{X_n - \beta_n}{\alpha_n} \xrightarrow{d} V,$$

entonces existen constantes  $A > 0$  y  $B \in \mathbb{R}$  tales que, cuando  $n \rightarrow \infty$ ,

$$\frac{\alpha_n}{a_n} \rightarrow A > 0, \quad \frac{\beta_n - b_n}{a_n} \rightarrow B, \quad (1.22)$$

y

$$H(x) = G(Ax + B), \quad V \stackrel{d}{=} \frac{U - B}{A}. \quad (1.23)$$

b) Recíprocamente, si (1.22) vale, entonces cualquiera de las relaciones en (1.21) implica la otra y (1.23) vale.

*Demostración*

Veamos primero la demostración de (b). Supongamos que

$$G_n(x) := F_n(a_n x + b_n) \rightarrow G(x)$$

y

$$\frac{\alpha_n}{a_n} \rightarrow A > 0, \quad \frac{\beta_n - b_n}{a_n} \rightarrow B,$$

entonces

$$F_n(\alpha_n x + \beta_n) = G_n\left(\frac{\alpha_n}{a_n} x + \frac{\beta_n - b_n}{a_n}\right).$$

Escogemos  $x \in \mathcal{C}(G(A \cdot + B))$ . Supongamos que  $x > 0$ , un argumento similar sirve si  $x \leq 0$ . Dado  $\varepsilon > 0$  para  $n$  grande tenemos

$$(A - \varepsilon)x + B - \varepsilon \leq \frac{\alpha_n}{a_n} x + \frac{\beta_n - b_n}{a_n} \leq (A + \varepsilon)x + B + \varepsilon$$

y en consecuencia

$$\limsup_{n \rightarrow \infty} F_n(\alpha_n x + \beta_n) \leq \limsup_{n \rightarrow \infty} G_n((A + \varepsilon)x + B + \varepsilon).$$

Por lo tanto, para cualquier  $z \in \mathcal{C}(G)$  con  $z > (A + \varepsilon)x + B + \varepsilon$  tenemos

$$\limsup_{n \rightarrow \infty} F_n(\alpha_n x + \beta_n) \leq \limsup_{n \rightarrow \infty} G_n(z) = G(z).$$

En consecuencia,

$$\limsup_{n \rightarrow \infty} F_n(\alpha_n x + \beta_n) \leq \inf\{G(z) : z > (A + \varepsilon)x + B + \varepsilon, z \in \mathcal{C}(G)\}.$$

y como  $\varepsilon > 0$  es arbitrario,

$$\limsup_{n \rightarrow \infty} F_n(\alpha_n x + \beta_n) \leq \inf\{G(z) : z > Ax + B\} = G(Ax + B)$$

por la continuidad por la derecha de  $G$ . De manera similar,

$$\begin{aligned} \liminf_{n \rightarrow \infty} F_n(\alpha_n x + \beta_n) &\geq \liminf_{n \rightarrow \infty} G_n((A - \varepsilon)x + B - \varepsilon) \\ &\geq \liminf_{n \rightarrow \infty} G_n(z) = G(z) \end{aligned}$$

para cualquier  $z < (A - \varepsilon)x + B - \varepsilon$ ,  $z \in \mathcal{C}(G)$ . Como estas desigualdades valen para todo  $\varepsilon > 0$ ,

$$\liminf_{n \rightarrow \infty} F_n(\alpha_n x + \beta_n) \geq \sup\{G(z) : z < Ax + B, z \in \mathcal{C}(G)\} = G(Ax + B)$$

porque  $Ax + B \in \mathcal{C}(G)$ .

Veamos ahora la demostración de la parte (a). Supongamos que

$$G_n(x) := F_n(a_n x + b_n) \rightarrow G(x), \quad H_n(x) := F_n(\alpha_n x + \beta_n) \rightarrow H(x).$$

Usando el lema 1.7 tenemos que  $G_n^{\leftarrow}(y) \rightarrow G^{\leftarrow}(y)$  para  $y \in \mathcal{C}(G^{\leftarrow})$  y  $H_n^{\leftarrow}(y) \rightarrow H^{\leftarrow}(y)$  para  $y \in \mathcal{C}(H^{\leftarrow})$ , y es fácil verificar que

$$G_n^{\leftarrow}(y) = \frac{F_n^{\leftarrow}(y) - b_n}{a_n}, \quad H_n^{\leftarrow}(y) = \frac{F_n^{\leftarrow}(y) - \beta_n}{\alpha_n}.$$

Por lo tanto

$$\begin{aligned} \frac{F_n^{\leftarrow}(y) - b_n}{a_n} &\rightarrow G^{\leftarrow}(y), \quad y \in \mathcal{C}(G^{\leftarrow}), \\ \frac{F_n^{\leftarrow}(y) - \beta_n}{\alpha_n} &\rightarrow H^{\leftarrow}(y), \quad y \in \mathcal{C}(H^{\leftarrow}). \end{aligned}$$

Como las f.d.  $G(x)$  y  $H(x)$  no están concentradas en un punto, podemos hallar  $y_1 < y_2$  con  $y_i \in \mathcal{C}(G^{\leftarrow}) \cap \mathcal{C}(H^{\leftarrow})$  para  $i = 1, 2$ , tales que

$$-\infty < G^{\leftarrow}(y_1) < G^{\leftarrow}(y_2) < \infty, \quad -\infty < H^{\leftarrow}(y_1) < H^{\leftarrow}(y_2) < \infty.$$

Por lo tanto, para  $i = 1, 2$  tenemos

$$\frac{F_n^{\leftarrow}(y_i) - b_n}{a_n} \rightarrow G^{\leftarrow}(y_i), \quad \frac{F_n^{\leftarrow}(y_i) - \beta_n}{\alpha_n} \rightarrow H^{\leftarrow}(y_i). \quad (1.24)$$

En las expresiones anteriores restamos las ecuaciones con  $i = 1$  de las expresiones con  $i = 2$  para obtener

$$\frac{F_n^{\leftarrow}(y_2) - F_n^{\leftarrow}(y_1)}{a_n} \rightarrow G^{\leftarrow}(y_2) - G^{\leftarrow}(y_1), \quad (1.25)$$

$$\frac{F_n^{\leftarrow}(y_2) - F_n^{\leftarrow}(y_1)}{\alpha_n} \rightarrow H^{\leftarrow}(y_2) - H^{\leftarrow}(y_1). \quad (1.26)$$

Ahora dividimos (1.25) entre (1.26) y obtenemos

$$\frac{\alpha_n}{a_n} \rightarrow \frac{G^{\leftarrow}(y_2) - G^{\leftarrow}(y_1)}{H^{\leftarrow}(y_2) - H^{\leftarrow}(y_1)} := A > 0.$$

Además, de (1.24) vemos que

$$\frac{F_n^{\leftarrow}(y_1) - b_n}{a_n} \rightarrow G^{\leftarrow}(y_1),$$

$$\frac{F_n^{\leftarrow}(y_1) - \beta_n}{a_n} = \frac{F_n^{\leftarrow}(y_1) - \beta_n}{\alpha_n} \frac{\alpha_n}{a_n} \rightarrow H^{\leftarrow}(y_1)A,$$

y restando obtenemos

$$\frac{\beta_n - b_n}{a_n} \rightarrow H^{\leftarrow}(y_1)A - G^{\leftarrow}(y_1) := B,$$

como queríamos ver, de modo que (1.22) vale. Por la parte (b) obtenemos (1.23). ■

**Observación 1.10** Una consecuencia de la demostración es que, a partir de (1.24), (1.25) y (1.26), una posible selección de las constantes de normalización es

$$a_n = F_n^{\leftarrow}(y_2) - F_n^{\leftarrow}(y_1), \quad b_n = F_n^{\leftarrow}(y_1).$$

El siguiente ejemplo muestra la importancia de la hipótesis de que las distribuciones límite no estén concentradas en un punto.

#### Ejemplo 1.14

Sea

$$G(x) = \begin{cases} 0, & \text{si } t < c, \\ 1, & \text{si } t \geq c. \end{cases}$$

Entonces,

$$G^{\leftarrow}(t) = \inf\{y : G(y) \geq t\} = \begin{cases} -\infty, & \text{si } t = 0 \\ c, & \text{si } 0 < t \leq 1, \\ \infty, & \text{si } t > 1. \end{cases}$$

El siguiente corolario es consecuencia inmediata del teorema de convergencia a familias.

**Corolario 1.10** *Sea  $F_n$  una sucesión de f. d. y  $a_n > 0$  y  $b_n$  sucesiones de constantes tales que*

$$F_n(a_n x + b_n) \rightarrow G(x) \tag{1.27}$$

*en todo punto de continuidad de  $G$ , que es un a f.d. propia y no está concentrada en un punto. Sean  $c_n > 0$  y  $d_n$  sucesiones de constantes tales que*

$$\frac{a_n}{c_n} \rightarrow 1, \quad \frac{d_n - b_n}{a_n} \rightarrow 0.$$

*Entonces (1.27) vale con  $c_n$  y  $d_n$  en lugar de  $a_n$  y  $b_n$ .*