

# Capítulo 5

## Esperanza Condicional y Martingalas

### 5.1. Preliminares

Comenzamos recordando algunos conceptos fundamentales sobre Espacios de Hilbert.

**Definición 5.1** Sea  $V$  un espacio vectorial real. Una función  $\langle \cdot, \cdot \rangle : V \times V \rightarrow \mathbb{R}$  es un *producto interno* si satisface

- (i)  $\langle x, x \rangle > 0, \forall x \neq 0$ .
- (ii)  $\langle x, y \rangle = \langle y, x \rangle$  para todo  $x, y \in V$ .
- (iii)  $\langle x, \alpha y + \beta z \rangle = \alpha \langle x, y \rangle + \beta \langle x, z \rangle$ .

Si  $\langle x, x \rangle \geq 0$  para todo  $x$  y (ii) y (iii) valen, decimos que  $\langle \cdot, \cdot \rangle$  es una forma bilineal simétrica semipositiva definida o un semi-producto interno.

El producto interno  $\langle \cdot, \cdot \rangle$  en  $V$  define una norma  $\|x\| = \langle x, x \rangle^{1/2}$ .

**Definición 5.2** Si  $(V, \langle \cdot, \cdot \rangle)$  es completo respecto a la norma definida por el producto interno, decimos que es un *Espacio de Hilbert*.

#### Ejemplo 5.1

Para  $f, g \in \mathcal{L}^2(\mu)$  definimos

$$\langle f, g \rangle = \int fg d\mu.$$

Si consideramos el espacio cociente  $L^2(\mu)$  y  $f, g$  se toman como representantes de sus clases de equivalencia  $\bar{f}, \bar{g}$  respectivamente, definimos  $\langle \bar{f}, \bar{g} \rangle = \langle f, g \rangle$ . Entonces  $\langle \cdot, \cdot \rangle$  es un producto interno en  $L^2$  y un semi-producto interno en  $\mathcal{L}^2$ . Sabemos que  $(L^2, \langle \cdot, \cdot \rangle)$  es un espacio de Hilbert.

**Definición 5.3** Sea  $V$  un espacio vectorial real con producto interno  $\langle \cdot, \cdot \rangle$ . Si  $W \subset V$ , el complemento ortogonal de  $W$  se define como

$$W^\perp = \{v \in V : \langle v, w \rangle = 0, \forall w \in W\}$$

**Teorema 5.1 (Descomposición Ortogonal)** Sea  $(V, \langle \cdot, \cdot \rangle)$  un espacio de Hilbert y  $W \subset V$  un subespacio lineal cerrado. Para todo  $x \in V$  hay una representación única  $x = y + z$  con  $y \in W$  y  $z \in W^\perp$ .

**Demostración.** Sea  $x \in V$ ,  $c = \inf\{\|x-w\| : w \in W\}$  y sea  $(w_n)_{n \geq 1}$  una sucesión en  $W$  con  $\|x-w_n\| \rightarrow c$  cuando  $n \rightarrow \infty$ . Usando la ley del paralelogramo obtenemos

$$\|w_m - w_n\|^2 = 2\|w_m - x\|^2 + 2\|w_n - x\|^2 - 4\left\|\frac{1}{2}(w_m + w_n) - x\right\|^2$$

Como  $W$  es un subespacio lineal,  $(w_m + w_n)/2 \in W$  y en consecuencia  $\|\frac{1}{2}(w_m + w_n) - x\| \geq c$ . Por lo tanto  $(w_n)_{n \geq 1}$  es una sucesión de Cauchy:  $\|w_m - w_n\| \rightarrow 0$  si  $m, n \rightarrow \infty$ . Como  $V$  es completo y  $W$  es cerrado, también es completo, de modo que existe  $y \in W$  con  $w_n \rightarrow y$  cuando  $n \rightarrow \infty$ . Sea ahora  $z = x - y$ , entonces  $\|z\| = \lim \|w_n - x\| = c$  por la continuidad de la norma.

Consideremos un  $w \in W \setminus \{0\}$  cualquiera. Definimos  $\rho = -\langle z, w \rangle / \|w\|^2$  y tenemos  $y + \rho w \in W$ . En consecuencia

$$c^2 \leq \|x - (y + \rho w)\|^2 = \|z\|^2 + \rho^2 \|w\|^2 - 2\rho \langle z, w \rangle = c^2 - \rho^2 \|w\|^2$$

y en conclusión  $\langle z, w \rangle = 0$  para todo  $w \in W$  y por lo tanto  $z \in W^\perp$ .

Falta ver la unicidad en la descomposición. Si  $x = y' + z'$  es otra descomposición ortogonal entonces  $y - y' \in W$  y  $z - z' \in W^\perp$  y además  $y - y' + z - z' = 0$ . En consecuencia

$$\begin{aligned} 0 &= \|y - y' + z - z'\|^2 = \|y - y'\|^2 + \|z - z'\|^2 + 2\langle y - y', z - z' \rangle \\ &= \|y - y'\|^2 + \|z - z'\|^2, \end{aligned}$$

de donde obtenemos que  $y = y'$  y  $z = z'$ . ■

**Teorema 5.2 (de Representación de Riesz-Fréchet)** Sea  $(V, \langle \cdot, \cdot \rangle)$  un espacio de Hilbert y  $F : V \rightarrow R$  una función. Las siguientes afirmaciones son equivalentes:

(i)  $F$  es lineal y continua.

(ii) Existe  $f \in V$  con  $F(x) = \langle x, f \rangle$  para todo  $x \in V$ .

El elemento  $f \in V$  en (ii) es único.

**Demostración.** (ii)  $\Rightarrow$  (i) Para cualquier  $f \in V$ , la función  $x \mapsto \langle x, f \rangle$  es lineal y continua por la definición del producto interno y la norma.

(i)  $\Rightarrow$  (ii) Para ver el recíproco, si  $F \equiv 0$  escogemos  $f = 0$ . Si  $F$  no es idénticamente cero, como es una función continua, el núcleo  $W = F^{-1}(\{0\})$  es un subespacio lineal cerrado y propio de  $V$ . Sea  $v \in V \setminus W$  y sea  $v = y + z$  para  $y \in W$  y  $z \in W^\perp$  la descomposición ortogonal de  $v$ . Entonces  $z \neq 0$  y  $F(z) = F(v) - F(y) = F(v) \neq 0$ . Por lo tanto podemos definir  $u = z/F(z) \in W^\perp$ . Claramente,  $F(u) = 1$  y para cualquier  $x \in V$ , tenemos

$$F(x - F(x)u) = F(x) - F(x)F(u) = 0.$$

Por lo tanto  $x - F(x)u \in W$  y  $\langle x - F(x)u, u \rangle = 0$ . En consecuencia

$$F(x) = \frac{1}{\|u\|^2} \langle x, u \rangle.$$

Definimos ahora  $f = u/\|u\|^2$ , entonces  $F(x) = \langle x, f \rangle$  para todo  $x \in V$ .

Finalmente, para ver la unicidad, sea  $\langle x, f \rangle = \langle x, g \rangle$  para todo  $x \in V$ . Si ponemos  $x = f - g$  tenemos  $0 = \langle f - g, f - g \rangle$  de donde obtenemos que  $f = g$ . ■

## 5.2. El Teorema de Radon-Nikodym

Sea  $\mu, \nu$  medidas sobre  $(\Omega, \mathcal{F})$ . Decimos que la función medible  $f : \Omega \rightarrow [0, \infty)$  es una densidad de  $\nu$  respecto de  $\mu$  si para todo  $A \in \mathcal{F}$ ,

$$\nu(A) = \int_A f d\mu \quad (5.1)$$

Por otro lado, dada cualquier función medible  $f : \Omega \rightarrow [0, \infty)$ , la ecuación (5.1) define una medida en  $(\Omega, \mathcal{F})$ . En este caso, si  $g : \Omega \rightarrow [0, \infty]$  es medible entonces

$$\int g d\nu = \int gf d\mu, \quad (5.2)$$

de modo que  $g \in \mathcal{L}(\nu)$  si y sólo si  $gf \in \mathcal{L}(\mu)$ , y en este caso (5.2) vale.

**Teorema 5.3** *Sea  $\nu$  una medida  $\sigma$ -finita. Si  $f_1$  y  $f_2$  son densidades de  $\nu$  respecto de  $\mu$ , entonces  $f_1 = f_2$  c.s. $(\mu)$ . Por lo tanto la densidad es única salvo por diferencias en conjuntos  $\mu$ -nulos.*

**Demostración.** Sea  $\Omega = \cup_{n \geq 1} E_n$  una descomposición del espacio  $\Omega$  en subconjuntos medibles de medida finita. Como la descomposición es numerable, basta con demostrar que  $f_1 = f_2$  c.s. $(\mu)$  en los conjuntos  $E_n$ . Sea  $E$  cualquiera de estos conjuntos y sea  $A = E \cap \{f_1 > f_2\}$ , entonces  $\nu(A) < \infty$ . Por lo tanto

$$\int_A (f_1 - f_2) d\mu = \nu(A) - \nu(A) = 0$$

y como en el conjunto  $A$  el integrando no es nulo, necesariamente  $\mu(A) = 0$ . De manera similar se demuestra que  $\mu(\{f_1 < f_2\}) = 0$  y en consecuencia  $f_1 = f_2$  c.s. $(\mu)$ . ■

Usaremos la notación  $d\nu/d\mu$  para la densidad de  $\nu$  respecto de  $\mu$ .

**Definición 5.4** Sea  $\mu$  y  $\nu$  dos medidas sobre  $(\Omega, \mathcal{F})$ . Decimos que  $\nu$  es *absolutamente continua* respecto de  $\mu$  ( $\nu \ll \mu$ ) si  $\nu(A) = 0$  para todo  $A \in \mathcal{F}$  con  $\mu(A) = 0$ .

Decimos que las medidas  $\mu$  y  $\nu$  son equivalentes ( $\mu \approx \nu$ ) si  $\nu \ll \mu$  y  $\mu \ll \nu$ .

Decimos que  $\nu$  es singular respecto de  $\mu$  ( $\nu \perp \mu$ ) si existe un conjunto medible  $A$  tal que  $\mu(A) = 0$  y  $\nu(A^c) = 0$ .

### Ejemplos 5.2

1. Sea  $\mu$  una medida sobre  $(\mathbb{R}, \mathcal{B})$  con densidad  $f$  respecto de la medida de Lebesgue  $m$ . Entonces  $\mu(A) = \int_A f dm = 0$  para todo  $A \in \mathcal{B}$  con  $m(A) = 0$ , de modo que  $\mu \ll m$ . Por otro lado si  $f > 0$  c.s. respecto de la medida de Lebesgue, entonces  $\mu(A) = \int_A f dm > 0$  si  $m(A) > 0$ , y en consecuencia  $\mu \approx m$ . En cambio, si  $f$  se anula en un conjunto de medida de Lebesgue positiva, como  $\mu(\{f = 0\}) = 0$  pero  $m(\{f = 0\}) > 0$ , la medida de Lebesgue no es absolutamente continua respecto de la medida  $\mu$ .
2. La distribución de Poisson está concentrada en el conjunto  $\{0, 1, 2, \dots\}$  que tiene medida 0, de modo que es singular respecto de  $m$ .

**Teorema 5.4 (de Descomposición de Lebesgue)** *Sea  $\mu$  y  $\nu$  medidas  $\sigma$ -finitas en  $(\Omega, \mathcal{F})$ . Entonces  $\nu$  puede descomponerse de manera única en una parte absolutamente continua  $\nu_a$  y una parte singular  $\nu_s$  respecto de  $\mu$ :*

$$\nu = \nu_a + \nu_s, \quad \text{donde } \nu_a \ll \mu \text{ y } \nu_s \perp \mu.$$

$\nu_a$  tiene densidad  $\frac{d\nu_a}{d\mu}$  que es medible y finita c.s. $(\mu)$ .

**Demostración.** Basta con hacer la demostración en el caso en el cual ambas medidas son finitas. Consideremos el funcional lineal  $T : \mathcal{L}^2(\Omega, \mathcal{F}, \mu + \nu) \rightarrow \mathbb{R}$  definido por

$$T(h) = \int h \, d\nu.$$

Este funcional es acotado ya que, usando la desigualdad de Cauchy-Schwarz,

$$\begin{aligned} |T(h)| &= \left| \int h \, d\nu \right| \leq \left( \int h^2 \, d\nu \right)^{1/2} \left( \int 1 \, d\nu \right)^{1/2} \\ &\leq \nu^{1/2}(\Omega) \|h\|_{L^2(\nu)} \leq \nu^{1/2}(\Omega) \|h\|_{L^2(\mu+\nu)} \end{aligned}$$

y por lo tanto es continuo. Por el teorema de representación de Riesz-Fréchet, existe  $g \in \mathcal{L}^2(\Omega, \mathcal{F}, \mu + \nu)$  tal que para todo  $h \in \mathcal{L}^2(\Omega, \mathcal{F}, \mu + \nu)$ ,

$$\int h \, d\nu = \int hg \, d(\mu + \nu) \quad (5.3)$$

o equivalentemente, para todo  $f \in \mathcal{L}^2(\Omega, \mathcal{F}, \mu + \nu)$ ,

$$\int f(1-g) \, d(\mu + \nu) = \int f \, d\mu \quad (5.4)$$

Si en (5.3) ponemos  $h = \mathbf{1}_{\{g < 0\}}$ , entonces  $g \geq 0$  c.s.  $(\mu + \nu)$ . Si en cambio ponemos  $f = \mathbf{1}_{\{g > 1\}}$  en (5.4), obtenemos que  $g \leq 1$  c.s.  $(\mu + \nu)$  y en consecuencia  $0 \leq g \leq 1$ .

Sea ahora  $f \geq 0$  medible y sea  $(f_n)_{n \geq 1}$  una sucesión de funciones medibles no-negativas en  $\mathcal{L}^2(\Omega, \mathcal{F}, \mu + \nu)$  con  $f_n \uparrow f$ . Por el teorema de convergencia monótona aplicado a la medida  $(1-g)(\mu + \nu)$ , obtenemos que (5.4) vale para toda  $f \geq 0$  medible. De manera similar se demuestra que (5.3) vale para toda  $h \geq 0$  medible.

Sea  $E = g^{-1}(\{1\})$ . Si ponemos  $f = \mathbf{1}_E$  en (5.4) entonces obtenemos  $\mu(E) = 0$ . Definimos las medidas  $\nu_a$  y  $\nu_s$  para  $A \in \mathcal{F}$  por

$$\nu_a(A) = \nu(A \setminus E) \quad \text{y} \quad \nu_s(A) = \nu(A \cap E)$$

Entonces  $\nu = \nu_a + \nu_s$  y  $\nu_s(\Omega \setminus E) = 0$ , de modo que  $\nu_s \perp \mu$ . Si tenemos que  $A \cap E = \emptyset$  y  $\mu(A) = 0$  entonces  $\int \mathbf{1}_A \, d\mu = 0$ . Por (5.4) también se tiene que

$$\int_A (1-g) \, d(\mu + \nu) = 0$$

Por otro lado tenemos que  $1-g > 0$  en  $A$ , de modo que  $\mu(A) + \nu(A) = 0$  y  $\mu(A) = \nu(A) = 0$ . Más generalmente, si  $B$  es medible con  $\mu(B) = 0$  entonces  $\mu(B \setminus E) = 0$  y en consecuencia  $\nu_a(B) = \nu_a(B \setminus E) = 0$ . En consecuencia  $\nu_a \ll \mu$  y  $\nu = \nu_a + \nu_s$  es la descomposición que buscábamos.

Para obtener la densidad de  $\nu_a$  respecto de  $\mu$ , definimos

$$f = \frac{g}{1-g} \mathbf{1}_{\Omega \setminus E}.$$

Para cualquier  $A \in \mathcal{F}$ , por (5.3) y (5.4) con  $h = \mathbf{1}_{A \setminus E}$

$$\int_A f \, d\mu = \int_{A \cap E^c} g \, d(\mu + \nu) = \nu(A \setminus E) = \nu_a(A)$$

de modo que  $f = \frac{d\nu_a}{d\mu}$ . ■

**Corolario 5.1 (Teorema de Radon-Nikodym)** *Si  $\mu$  y  $\nu$  son medidas  $\sigma$ -finitas en  $(\Omega, \mathcal{F})$ , existe  $f$  medible tal que*

$$\nu(A) = \int_A f \, d\mu, \quad \forall A \in \mathcal{F},$$

si y sólo si  $\nu \ll \mu$ .

Escribimos  $f = \frac{d\nu}{dP}$  y también  $d\nu = f dP$ .

**Corolario 5.2** Sean  $P$  y  $Q$  medidas de probabilidad en  $(\Omega, \mathcal{F})$  tales que  $Q \ll P$ . Sea  $\mathcal{G} \subset \mathcal{F}$  una sub- $\sigma$ -álgebra. Sean  $Q|_{\mathcal{G}}$  y  $P|_{\mathcal{G}}$  las restricciones de  $Q$  y  $P$  a  $\mathcal{G}$ . Entonces en  $(\Omega, \mathcal{G})$

$$Q|_{\mathcal{G}} \ll P|_{\mathcal{G}}$$

y

$$\frac{dQ|_{\mathcal{G}}}{dP|_{\mathcal{G}}} \text{ es } \mathcal{G}\text{-medible.}$$

### 5.3. Esperanza Condicional

**Definición 5.5** Sea  $(\Omega, \mathcal{F}, P)$  un espacio de probabilidad,  $X$  una v.a. integrable y  $\mathcal{G} \subset \mathcal{F}$  una sub- $\sigma$ -álgebra. La *esperanza condicional* de  $X$  dada la  $\sigma$ -álgebra  $\mathcal{G}$  es cualquier variable aleatoria  $Z$  medible respecto a  $\mathcal{G}$  e integrable tal que

$$\int_A Z dP = \int_A X dP \quad \forall A \in \mathcal{G} \quad (5.5)$$

**Observación 5.1** (a) Usamos la notación  $E(X|\mathcal{G})$  para la esperanza condicional de  $X$  dada  $\mathcal{G}$ .

(b) La esperanza condicional no es única: Cualquier variable aleatoria  $Y$  que sea equivalente a  $Z$  en el sentido de ser igual a ella casi seguramente tiene las mismas propiedades.

(c) Observamos que las integrales de  $X$  y  $Z$  sobre los conjuntos  $A \in \mathcal{G}$  coinciden. Sin embargo  $X \in \mathcal{F}$  mientras que  $Z \in \mathcal{G}$ .

(d) La esperanza condicional no es un número, es una variable aleatoria.

Veamos cuál es el sentido matemático de esta definición. Supongamos inicialmente que  $X \geq 0$  es integrable y definamos

$$\nu(A) = \int_A X dP, \quad A \in \mathcal{F}.$$

Entonces  $\nu$  es finita y absolutamente continua respecto a  $P$ . Por lo tanto

$$\nu|_{\mathcal{G}} \ll P|_{\mathcal{G}}.$$

Por el teorema de Radon-Nikodym sabemos que existe la derivada y ponemos

$$E(X|\mathcal{G}) = \frac{d\nu|_{\mathcal{G}}}{dP|_{\mathcal{G}}}$$

la cual es  $\mathcal{G}$ -medible por el corolario 5.2. Para cualquier  $G \in \mathcal{G}$  se tiene

$$\begin{aligned} \int_G X dP &= \nu|_{\mathcal{G}}(G) = \nu(G) = \int_G \frac{d\nu|_{\mathcal{G}}}{dP|_{\mathcal{G}}} dP|_{\mathcal{G}} \\ &= \int_G \frac{d\nu|_{\mathcal{G}}}{dP|_{\mathcal{G}}} dP \\ &= \int_G E(X|\mathcal{G}) dP \end{aligned}$$

que es la ecuación (5.5).

Si  $X$  no es positiva entonces

$$E(X|\mathcal{G}) = E(X^+|\mathcal{G}) - E(X^-|\mathcal{G})$$

satisface las condiciones de la definición.

**Definición 5.6** Definimos la probabilidad condicional dada la (sub-) $\sigma$ -álgebra  $\mathcal{G}$  por

$$P(A|\mathcal{G}) = E(\mathbf{1}_A|\mathcal{G})$$

para todo  $A \in \mathcal{F}$ . Por lo tanto  $P(A|\mathcal{G})$  es una variable aleatoria tal que

- (a)  $P(A|\mathcal{G})$  es  $\mathcal{G}$ -medible e integrable.
- (b)  $P(A|\mathcal{G})$  satisface

$$\int_G P(A|\mathcal{G}) dP = P(A \cap G), \quad (5.6)$$

para todo  $G \in \mathcal{G}$ .

**Definición 5.7** Sea  $\{X_t, t \in T\}$  una colección de v.a. definidas en el espacio  $(\Omega, \mathcal{F}, P)$ , donde  $T$  es algún conjunto de índices. Sea

$$\mathcal{G} = \sigma(X_t, t \in T)$$

la  $\sigma$ -álgebra generada por  $\{X_t, t \in T\}$ . Definimos

$$E(X|X_t, t \in T) = E(X|\mathcal{G}).$$

### Ejemplo 5.3

Sea  $\{\Lambda_i, i \geq 1\}$  una partición de  $\Omega$ , de modo que  $\Lambda_i \cap \Lambda_j = \emptyset$  si  $i \neq j$  y  $\cup_1^\infty \Lambda_n = \Omega$ . Definimos  $\mathcal{G} = \sigma(\Lambda_i, i \geq 1)$  de modo que podemos describir a esta  $\sigma$ -álgebra como

$$\mathcal{G} = \left\{ \bigcup_{i \in J} \Lambda_i : J \subset \mathbb{N} \right\}$$

Para  $X \in L^1(\Omega)$  definimos

$$\alpha_n = \alpha_n(X) = E(X|\Lambda_n) = \int X P(d\omega|\Lambda_n) = \frac{1}{P(\Lambda_n)} \int_{\Lambda_n} X dP$$

si  $P(\Lambda_n) > 0$  y  $\alpha_n = 0$  si  $P(\Lambda_n) = 0$ . Veamos que

$$(a) E(X|\mathcal{G}) \stackrel{c.s.}{=} \sum_{n=1}^{\infty} \alpha_n(X) \mathbf{1}_{\Lambda_n}.$$

$$(b) \text{ Para cualquier } A \in \mathcal{F}, P(A|\mathcal{G}) \stackrel{c.s.}{=} \sum_{n=1}^{\infty} P(A|\Lambda_n) \mathbf{1}_{\Lambda_n}.$$

Para verificar (a) observamos que

$$\sum_{n=1}^{\infty} \alpha_n(X) \mathbf{1}_{\Lambda_n} \in \mathcal{G}.$$

Ahora escogemos  $\Lambda \in \mathcal{G}$  y basta mostrar que

$$\int_{\Lambda} E(X|\mathcal{G}) dP = \int_{\Lambda} \left( \sum_{n=1}^{\infty} \alpha_n(X) \mathbf{1}_{\Lambda_n} \right) dP = \int_{\Lambda} X dP. \quad (5.7)$$

Como  $\Lambda \in \mathcal{G}$ ,  $\Lambda$  es de la forma  $\Lambda = \cup_{i \in J} \Lambda_i$  para algún  $J \subset \mathbb{N}$ . Veamos que la forma propuesta en (a)

satisface (5.7).

$$\begin{aligned}
\int_{\Lambda} \sum_{n=1}^{\infty} \alpha_n(X) \mathbf{1}_{\Lambda_n} dP &= \sum_{n \geq 1} \sum_{i \in J} \int_{\Lambda_i} \alpha_n(X) \mathbf{1}_{\Lambda_n} dP \\
&= \sum_{n \geq 1} \sum_{i \in J} \alpha_n(X) P(\Lambda_i \cap \Lambda_n) \\
&= \sum_{i \in J} \alpha_n(X) P(\Lambda_i) \\
&= \sum_{i \in J} \frac{1}{P(\Lambda_i)} \int_{\Lambda_i} X dP P(\Lambda_i) \\
&= \sum_{i \in J} \int_{\Lambda_i} X dP = \int_{\cup_{i \in J} \Lambda_i} X dP \\
&= \int_{\Lambda} X dP.
\end{aligned}$$

Esto demuestra (a). Para obtener (b) basta poner  $X = \mathbf{1}_A$ .

#### Ejemplo 5.4

Sea  $X$  una v.a. discreta con valores posibles  $x_1, x_2, \dots$ . Entonces para  $A \in \mathcal{F}$

$$\begin{aligned}
P(A|X) &= P(A|\sigma(X)) = P(A|\sigma(\{X = x_i\}, i \geq 1)) \\
&= \sum_{i=1}^{\infty} P(A|X = x_i) \mathbf{1}_{\{X=x_i\}}
\end{aligned}$$

#### Ejemplo 5.5

Supongamos que  $X$  e  $Y$  son v.a. cuya distribución conjunta es absolutamente continua con densidad  $f(x, y)$ , de modo que para  $A \in \mathcal{B}^2$

$$P[(X, Y) \in A] = \iint_A f(x, y) dx dy.$$

¿Quién es  $P(Y \in C|X)$  para  $C \in \mathcal{B}$ ? Sea  $\mathcal{G} = \sigma(X)$  y

$$f_X(x) = \int_{\mathbb{R}} f(x, y) dy$$

la densidad marginal de  $X$  y definimos

$$\phi(x) = \begin{cases} \frac{1}{f_X(x)} \int_C f(x, y) dy, & \text{si } f_X(x) > 0, \\ 0 & \text{si } f_X(x) = 0. \end{cases}$$

Veamos que  $P(Y \in C|X) = \phi(X)$ . En primer lugar observamos que  $\int_C f(X, y) dy$  es  $\sigma(X)$ -medible y por lo tanto  $\phi(X)$  es  $\sigma(X)$ -medible. Falta demostrar que para cualquier  $\Lambda \in \sigma(X)$ ,

$$\int_{\Lambda} \phi(X) dP = P[(Y \in C) \cap \Lambda].$$

Como  $\Lambda \in \sigma(X)$ , podemos escribir  $\Lambda = \{X \in A\}$  para algún  $A \in \mathcal{B}$ . Por el teorema de transformación tenemos

$$\int_{\Lambda} \phi(X) dP = \int_{X^{-1}(A)} \phi(X) dP = \int_A \phi(x) dP_X(x)$$

y como existe la densidad conjunta de  $(X, Y)$  obtenemos que esta expresión es igual a

$$\begin{aligned}
&= \int_A \phi(x) \left( \int_{\mathbb{R}} f(x, y) dy \right) dx \\
&= \int_{A \cap \{x: f_X(x) > 0\}} \phi(x) f_X(x) dx + \int_{A \cap \{x: f_X(x) = 0\}} \phi(x) f_X(x) dx \\
&= \int_{A \cap \{x: f_X(x) > 0\}} \phi(x) f_X(x) dx \\
&= \int_{A \cap \{x: f_X(x) > 0\}} \frac{1}{f_X(x)} \int_C f(x, y) dy f_X(x) dx \\
&= \int_{A \cap \{x: f_X(x) > 0\}} \left( \int_C f(x, y) dy \right) dx \\
&= \int_A \left( \int_C f(x, y) dy \right) dx = P(X \in A, Y \in C) \\
&= P((Y \in C) \cap \Lambda)
\end{aligned}$$

### 5.3.1. Propiedades de la Esperanza Condicional

**Proposición 5.1** Sean  $X$  e  $Y$  v.a. integrables,  $\mathcal{G} \subset \mathcal{F}$  y  $a, b, c$  números reales. Entonces

- (a)  $E(E(X|\mathcal{G})) = E(X)$ .
- (b)  $E(aX + bY|\mathcal{G}) \stackrel{c.s.}{=} aE(X|\mathcal{G}) + bE(Y|\mathcal{G})$ .
- (c) Si  $X \in \mathcal{G}$  entonces  $E(X|\mathcal{G}) \stackrel{c.s.}{=} X$ .
- (d)  $E(c|\mathcal{G}) \stackrel{c.s.}{=} c$ .
- (e)  $E(X|\{\emptyset, \Omega\}) \stackrel{c.s.}{=} E(X)$ .
- (f) Si  $X \geq 0$  c.s. entonces  $E(X|\mathcal{G}) \geq 0$  c.s.
- (g) Si  $X \leq Y$  c.s. entonces  $E(X|\mathcal{G}) \leq E(Y|\mathcal{G})$  c.s.
- (h)  $|E(X|\mathcal{G})| \leq E(|X|\mathcal{G})$ .
- (i) Si  $X$  es independiente de  $\mathcal{G}$  entonces  $E(X|\mathcal{G}) = E(X)$  c.s.

**Demostración.** La primera propiedad se obtiene haciendo  $\Lambda = \Omega$  en (5.5). (b) es

$$\begin{aligned}
\int_{\Lambda} E(aX + bY|\mathcal{G}) dP &= \int_{\Lambda} (aX + bY) dP = a \int_{\Lambda} X dP + b \int_{\Lambda} Y dP \\
&= a \int_{\Lambda} E(X|\mathcal{G}) dP + b \int_{\Lambda} E(Y|\mathcal{G}) dP \\
&= \int_{\Lambda} [aE(X|\mathcal{G}) + bE(Y|\mathcal{G})] dP.
\end{aligned}$$

(c) es consecuencia de la identidad trivial

$$\int_{\Lambda} X dP = \int_{\Lambda} X dP$$

y como  $X$  es  $\mathcal{G}$ -medible satisface las condiciones de la definición. Como toda constante es  $\mathcal{G}$ -medible, (d) es inmediata de (c).

Para (e)

$$\int_{\Lambda} X dP = \begin{cases} 0, & \text{para } \Lambda = \emptyset, \\ E(X), & \text{para } \Lambda = \Omega, \end{cases}$$

es decir

$$\int_{\Lambda} X dP = \int_{\Lambda} E(X) dP, \quad \text{para todo } \Lambda \in \{\emptyset, \Omega\},$$

de modo que podemos reemplazar  $E(X|\mathcal{G})$  por  $E(X)$ . (f) se obtiene por

$$\int_{\Lambda} E(X|\mathcal{G}) dP = \int_{\Lambda} X dP \geq 0.$$

Usando esta propiedad y (b) aplicada a  $Y - X$  obtenemos (g). Para (h) tenemos

$$|E(X|\mathcal{G})| = |E(X^+|\mathcal{G}) - E(X^-|\mathcal{G})| \leq E(X^+|\mathcal{G}) + E(X^-|\mathcal{G}) = E(|X|\mathcal{G}).$$

Para probar (i) observamos que  $E(X) \in \mathcal{G}$  y que para cualquier  $\Lambda \in \mathcal{G}$ ,

$$\int_{\Lambda} E(X) dP = E(X)P(\Lambda) = E(X\mathbf{1}_{\Lambda}) = \int_{\Omega} X\mathbf{1}_{\Lambda} dP = \int_{\Lambda} X dP.$$

Esta relación dice que  $E(X)$  satisface (5.5). ■

La siguiente proposición presenta las versiones condicionales del TCM, el lema de Fatou y el TCD.

**Proposición 5.2** (a) Si  $0 \leq X_n \uparrow X \in L^1(\Omega)$  cuando  $n \rightarrow \infty$  entonces  $E(X_n|\mathcal{G}) \uparrow E(X|\mathcal{G})$  cuando  $n \rightarrow \infty$ .

(b) Si  $X_n \downarrow X$  cuando  $n \rightarrow \infty$  y  $X_1, X \in L^1(\Omega)$  entonces  $E(X_n|\mathcal{G}) \downarrow E(X|\mathcal{G})$  cuando  $n \rightarrow \infty$ .

(c) Si  $\{X_n, n \geq 1\}$  son no-negativas e integrables, entonces

$$E(\liminf_{n \rightarrow \infty} X_n|\mathcal{G}) \leq \liminf_{n \rightarrow \infty} E(X_n|\mathcal{G}) \quad c.s.$$

(d) Si  $X_n \leq Y \in L^1$  para todo  $n$ , entonces

$$E(\limsup_{n \rightarrow \infty} X_n|\mathcal{G}) \geq \limsup_{n \rightarrow \infty} E(X_n|\mathcal{G}) \quad c.s.$$

(e) Si  $|X_n| \leq Y \in L^1$  y  $X_n \xrightarrow{c.s.} X$  cuando  $n \rightarrow \infty$ , entonces

$$E(X_n|\mathcal{G}) \xrightarrow{c.s.} E(X|\mathcal{G}) \quad \text{cuando } n \rightarrow \infty.$$

**Demostración.** Sabemos por la proposición anterior que  $E(X_n|\mathcal{G})$  es monótona creciente y no-negativa, de modo que el límite  $Z = \lim_{n \rightarrow \infty} E(X_n|\mathcal{G})$  existe. Usando la relación (5.5) y el TCM obtenemos para  $\Lambda \in \mathcal{G}$

$$\begin{aligned} \int_{\Lambda} Z dP &= \int_{\Lambda} \lim_{n \rightarrow \infty} E(X_n|\mathcal{G}) dP = \lim_{n \rightarrow \infty} \int_{\Lambda} E(X_n|\mathcal{G}) dP \\ &= \lim_{n \rightarrow \infty} \int_{\Lambda} X_n dP = \int_{\Lambda} \lim_{n \rightarrow \infty} X_n dP = \int_{\Lambda} X dP. \end{aligned}$$

Esto demuestra (a) y (b) sigue cambiando signos. Para demostrar (c) ponemos  $Z_n = \inf_{k \geq n} X_k \leq X_n$  y observamos que  $Z_n \xrightarrow{c.s.} \liminf_{n \rightarrow \infty} X_n$  monótonicamente. Por la proposición anterior

$$E(X_n|\mathcal{G}) \geq E(Z_n|\mathcal{G}) \uparrow E(\liminf_{n \rightarrow \infty} X_n|\mathcal{G})$$

de donde (c) sigue. Para (d) observamos que  $Y - X_n \geq 0$  es integrable y podemos aplicar (c). Finalmente, para (e) usamos (c) y (d). ■

**Proposición 5.3** Si  $X$  y  $XY$  son integrables,  $Y \in \mathcal{G}$ , entonces

$$E(XY|\mathcal{G}) \stackrel{c.s.}{=} Y E(X|\mathcal{G}).$$

**Demostración.** Supongamos inicialmente que  $X$  e  $Y$  son no-negativas. Para  $Y = \mathbf{1}_A$ , con  $A \in \mathcal{G}$ , también se tiene que  $A \cap \Lambda \in \mathcal{G}$ , para todo  $\Lambda \in \mathcal{G}$  y usando (5.5)

$$\int_{\Lambda} Y E(X|\mathcal{G}) dP = \int_{\Lambda \cap A} E(X|\mathcal{G}) dP = \int_{\Lambda \cap A} X dP = \int_{\Lambda} XY dP$$

y esto demuestra la relación para indicadores, y por linealidad para variables simples. Si  $\{Y_n, n \geq 1\}$  son v.a. simples tales que  $Y_n \uparrow Y$  c.s. cuando  $n \rightarrow \infty$ , se tiene que  $XY_n \uparrow XY$  y  $Y_n E(X|\mathcal{G}) \uparrow Y E(X|\mathcal{G})$  c.s. cuando  $n \rightarrow \infty$ , y la conclusión sigue por convergencia monótona. El caso general sigue usando la descomposición  $X = X^+ - X^-$  y  $Y = Y^+ - Y^-$ . ■

Muchas propiedades de martingalas se demuestran condicionando sucesivamente. El siguiente lema es fundamental para este procedimiento

**Lema 5.1 (Suavizamiento)** *Sea  $\mathcal{H} \subset \mathcal{G} \subset \mathcal{F}$ , entonces*

$$E(E(X|\mathcal{G})|\mathcal{H}) = E(X|\mathcal{H}) = E(E(X|\mathcal{H})|\mathcal{G}) \quad \text{c.s.}$$

**Demostración.** Como  $E(X|\mathcal{H}) \in \mathcal{G}$  la segunda igualdad es consecuencia de la proposición 5.1 (c). Para demostrar la primera sea  $\Lambda \in \mathcal{H} \subset \mathcal{G}$ . Usando la relación (5.5) obtenemos

$$\int_{\Lambda} E(E(X|\mathcal{G})|\mathcal{H}) dP = \int_{\Lambda} E(X|\mathcal{G}) dP = \int_{\Lambda} X dP = \int_{\Lambda} E(X|\mathcal{H}) dP$$

Para entender por qué el nombre del lema, recordemos el ejemplo 5.3 en el cual  $\mathcal{G} = \sigma(\Lambda_n, n \geq 1)$ , donde  $\{\Lambda_n, n \geq 1\}$  es una partición numerable de  $\Omega$ . Entonces

$$E(X|\mathcal{G}) = \sum_{n=1}^{\infty} \alpha_n(X) \mathbf{1}_{\Lambda_n},$$

de modo que  $E(X|\mathcal{G})$  es constante en cada conjunto  $\Lambda_n$ .

Si  $\mathcal{G}_1 \subset \mathcal{G}_2$  y ambas son generadas por particiones numerables  $\{\Lambda_n^{(1)}, n \geq 1\}$  y  $\{\Lambda_n^{(2)}, n \geq 1\}$ , entonces  $\Lambda_n^{(1)} \in \mathcal{G}_2$ , de modo que existe un conjunto de índices  $J \subset \mathbb{N}$  tal que  $\Lambda_n^{(1)} = \sum_{j \in J} \Lambda_j^{(2)}$ . Por lo tanto  $E(X|\mathcal{G}_1)$  es constante en  $\Lambda_n^{(1)}$  pero  $E(X|\mathcal{G}_2)$  puede cambiar de valor a medida que  $\omega$  se mueve entre los conjuntos  $\Lambda_j^{(1)}$ ,  $j \in J$ . Como función,  $E(X|\mathcal{G}_1)$  es más suave que  $E(X|\mathcal{G}_2)$ .

**Teorema 5.5** *Sea  $Y$  una v.a. con varianza finita y sea  $\mathcal{G}$  una sub- $\sigma$ -álgebra de  $\mathcal{F}$ . Entonces*

$$E[(Y - E(Y|\mathcal{G}))^2] = E[Y^2] - E[(E(Y|\mathcal{G}))^2]$$

**Demostración.** Usando la proposición 5.3 y el lema 5.1,

$$E(Y E(Y|\mathcal{G})) = E[E(Y E(Y|\mathcal{G}))|\mathcal{G}] = E[E(Y|\mathcal{G}) E(Y|\mathcal{G})] = E[E(Y|\mathcal{G})^2]$$

de modo que

$$E[(Y - E(Y|\mathcal{G}))^2] = E[Y^2] + E[(E(Y|\mathcal{G}))^2] - 2E[Y E(Y|\mathcal{G})] = E[Y^2] - E[(E(Y|\mathcal{G}))^2]$$

■

### Proyecciones

Sea  $\mathcal{G}$  una sub- $\sigma$ -álgebra de  $\mathcal{F}$ . Sea  $L^2(\mathcal{G})$  la clase de las variables aleatorias  $\mathcal{G}$ -medibles con segundo momento finito. Si  $X \in L^2(\mathcal{F})$  entonces  $E(X|\mathcal{G})$  es la proyección de  $X$  a  $L^2(\mathcal{G})$ , un subespacio de  $L^2(\mathcal{B})$ .

La proyección de  $X$  en  $L^2(\mathcal{G})$  es el (único) elemento de  $L^2(\mathcal{G})$  en el cual se alcanza

$$\inf_{Z \in L^2(\mathcal{G})} \|X - Z\|_2$$

Para alcanzar el ínfimo debe cumplirse que  $X - Z$  sea ortogonal a todas las variables del subespacio  $L^2(\mathcal{G})$ :

$$\langle Y, X - Z \rangle = 0, \quad \forall Y \in L^2(\mathcal{G}).$$

Es decir que

$$\int Y(X - Z) dP = 0, \quad \forall Y \in L^2(\mathcal{G}).$$

Si probamos  $Z = E(X|\mathcal{G})$  obtenemos

$$\begin{aligned} \int Y(X - Z) dP &= E(Y(X - E(X|\mathcal{G}))) \\ &= E(YX) - E(Y E(X|\mathcal{G})) \\ &= E(YX) - E(E(YX|\mathcal{G})) \\ &= E(YX) - E(YX) = 0. \end{aligned}$$

### 5.3.2. Desigualdades de Momentos Condicionales.

**Teorema 5.6** *Sea  $X$  e  $Y$  v.a. y supongamos que  $\mathcal{G}$  es una sub- $\sigma$ -álgebra  $\mathcal{F}$ . Las siguientes desigualdades de momentos valen c.s. siempre que los momentos correspondientes existan*

1.

$$E(|X + Y|^r|\mathcal{G}) \leq c_r (E(|X|^r|\mathcal{G}) + E(|Y|^r|\mathcal{G})),$$

donde  $c_r = 1$  para  $r \leq 1$  y  $c_r = 2^{r-1}$  para  $r \geq 1$ .

2. Hölder. Si  $1 < p < \infty$ ,  $p^{-1} + q^{-1} = 1$ ,

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

3. Minkowski

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

4. Jensen. Si  $g$  es una función convexa y  $g(X) \in L^1$ ,

$$g(E(X|\mathcal{G})) \leq E(g(X)|\mathcal{G}).$$

**Demostración.** Veamos la demostración de la desigualdad de Jensen. Consideremos la recta de soporte en  $x_0$ ; por convexidad debe estar por debajo de la gráfica de  $g$  de modo que

$$g(x_0) + \lambda(x_0)(x - x_0) \leq g(x) \tag{5.8}$$

donde  $\lambda(x_0)$  es la pendiente de la recta de soporte que pasa por  $(x_0, g(x_0))$ . Reemplazamos  $x_0$  por  $E(X|\mathcal{G})$  y  $x$  por  $X$  para obtener

$$g(E(X|\mathcal{G})) + \lambda(E(X|\mathcal{G}))(X - E(X|\mathcal{G})) \leq g(X) \tag{5.9}$$

Si no hay problemas de integrabilidad podemos tomar esperanza condicional respecto a  $\mathcal{G}$  en ambos lados de (5.9). Para el lado izquierdo obtenemos

$$\begin{aligned} g(\mathbf{E}(X|\mathcal{G})) + \mathbf{E}[\lambda(\mathbf{E}(X|\mathcal{G}))(X - \mathbf{E}(X|\mathcal{G}))|\mathcal{G}] &= g(\mathbf{E}(X|\mathcal{G})) + \lambda(\mathbf{E}(X|\mathcal{G})) \mathbf{E}(X - \mathbf{E}(X|\mathcal{G}))|\mathcal{G}) \\ &= g(\mathbf{E}(X|\mathcal{G})) \end{aligned}$$

donde usamos que  $\mathbf{E}(X - \mathbf{E}(X|\mathcal{G}))|\mathcal{G}) = 0$ . Por otro lado, al calcular la esperanza condicional del lado derecho de (5.9) obtenemos  $\mathbf{E}(g(X)|\mathcal{G})$ , y por lo tanto

$$g(\mathbf{E}(X|\mathcal{G})) \leq \mathbf{E}(g(X)|\mathcal{G}).$$

Para concluir veamos que no hay problemas de integrabilidad en (5.9). Observemos primero que podemos tomar  $\lambda(x)$  como la derivada por la derecha

$$\lim_{h \downarrow 0} \frac{g(x+h) - g(x)}{h}$$

que siempre existe y por convexidad es no-decreciente en  $x$ . Si podemos demostrar que  $\mathbf{E}(X|\mathcal{G})(\omega)$  es acotada como función de  $\omega$ , entonces también lo serían  $g(\mathbf{E}(X|\mathcal{G}))$  y  $\lambda(\mathbf{E}(X|\mathcal{G}))$ , de modo que todos los términos de (5.9) serían integrables. Sea ahora

$$X' = X \mathbf{1}_{\{| \mathbf{E}(X|\mathcal{G})| \leq n\}},$$

observamos que

$$\mathbf{E}(X'|\mathcal{G}) = \mathbf{E}(X \mathbf{1}_{\{| \mathbf{E}(X|\mathcal{G})| \leq n\}}|\mathcal{G}) = \mathbf{1}_{\{| \mathbf{E}(X|\mathcal{G})| \leq n\}} \mathbf{E}(X|\mathcal{G})$$

es acotado y podemos usar el resultado de la desigualdad de Jensen para esperanzas condicionales acotadas. Obtenemos

$$g(\mathbf{E}(X'|\mathcal{G})) \leq \mathbf{E}(g(X')|\mathcal{G}).$$

Por lo tanto, cuando  $n \rightarrow \infty$

$$\begin{aligned} \mathbf{E}(g(X')|\mathcal{G}) &= \mathbf{E}(g(X \mathbf{1}_{\{| \mathbf{E}(X|\mathcal{G})| \leq n\}})|\mathcal{G}) \\ &= \mathbf{E}(g(X \mathbf{1}_{\{| \mathbf{E}(X|\mathcal{G})| \leq n\}}) + g(0) \mathbf{1}_{\{| \mathbf{E}(X|\mathcal{G})| > n\}}|\mathcal{G}) \\ &= \mathbf{1}_{\{| \mathbf{E}(X|\mathcal{G})| \leq n\}} \mathbf{E}(g(X)|\mathcal{G}) + g(0) \mathbf{1}_{\{| \mathbf{E}(X|\mathcal{G})| > n\}} \\ &\rightarrow \mathbf{E}(g(X)|\mathcal{G}). \end{aligned}$$

Además, cuando  $n \rightarrow \infty$

$$g(\mathbf{E}(X'|\mathcal{G})) = g(\mathbf{1}_{\{| \mathbf{E}(X|\mathcal{G})| \leq n\}} \mathbf{E}(X|\mathcal{G})) \rightarrow g(\mathbf{E}(X|\mathcal{G}))$$

ya que  $g$  es continua. ■

**Proposición 5.4** Si  $X \in L^p$ , definimos  $\|X\|_p = (\mathbf{E}|X|^p)^{1/p}$  y supongamos que  $p \geq 1$ . Entonces

$$\|\mathbf{E}(X|\mathcal{G})\|_p \leq \|X\|_p. \quad (5.10)$$

Además, si  $X_n \rightarrow X$  en  $L^p$  entonces  $\mathbf{E}(X_n|\mathcal{G}) \rightarrow \mathbf{E}(X|\mathcal{G})$  en  $L^p$ .

**Demostración.** La desigualdad (5.10) vale si

$$(\mathbf{E}(|\mathbf{E}(X|\mathcal{G})|^p))^{1/p} \leq (\mathbf{E}(|X|^p))^{1/p}$$

o equivalentemente

$$\mathbf{E}(|\mathbf{E}(X|\mathcal{G})|^p) \leq \mathbf{E}(|X|^p).$$

A partir de la desigualdad de Jensen, si  $g$  es convexa,  $g(\mathbf{E}(X|\mathcal{G})) \leq \mathbf{E}(g(X)|\mathcal{G})$ . Como  $g(x) = |x|^p$  es convexa para  $p \geq 1$  obtenemos

$$\mathbf{E}(|\mathbf{E}(X|\mathcal{G})|^p) \leq \mathbf{E}(|X|^p).$$

Para ver la convergencia observamos que

$$\|\mathbf{E}(X_n|\mathcal{G}) - \mathbf{E}(X|\mathcal{G})\|_p = \|\mathbf{E}((X_n - X)|\mathcal{G})\|_p \leq \|X_n - X\|_p \rightarrow 0. \quad \blacksquare$$

## 5.4. Martingalas.

Comenzamos con un espacio de probabilidad  $(\Omega, \mathcal{F}, P)$ .

**Definición 5.8** Una sucesión  $\{\mathcal{F}_n, n \geq 0\}$  de sub- $\sigma$ -álgebras es una *filtración* si es una sucesión creciente, es decir,

$$\mathcal{F}_0 \subset \mathcal{F}_1 \subset \cdots \subset \mathcal{F}_n \subset \mathcal{F}_{n+1} \subset \cdots \subset \mathcal{F}.$$

Si interpretamos  $n$  como el tiempo,  $\mathcal{F}_n$  contiene la información disponible al tiempo  $n$ . También consideramos  $\mathcal{F}_\infty = \sigma(\cup_n \mathcal{F}_n)$ .

**Definición 5.9** Una sucesión  $\{X_n, n \geq 0\}$  de v.a. es *adaptada* a  $\{\mathcal{F}_n, n \geq 1\}$  si  $X_n \in \mathcal{F}_n$  para todo  $n$ . Si  $\mathcal{F}_n = \sigma(X_0, X_1, \dots, X_n)$  decimos simplemente que la sucesión es *adaptada* y llamamos a  $\{\mathcal{F}_n, n \geq 1\}$  la *filtración natural*.

**Definición 5.10** Una sucesión  $\{X_n, n \geq 0\}$  de v.a. es  $\mathcal{F}_n$ -*predecible* si  $X_n \in \mathcal{F}_{n-1}$  para todo  $n$ .

**Definición 5.11** Una sucesión  $\{A_n, n \geq 0\}$  de v.a. es un *proceso creciente* si  $A_0 = 0$ ,  $A_n \nearrow$  y  $\{A_n\}$  es predecible

**Definición 5.12** Una sucesión  $\{X_n, \mathcal{F}_n, n \geq 1\}$  donde  $X_n$  son v.a. integrables y  $\{\mathcal{F}_n\}$  es una filtración, es una *martingala* si  $X_n$  es adaptada a  $\mathcal{F}_n$  y se cumple que

$$E(X_{n+1}|\mathcal{F}_n) = X_n \quad c.s. \quad \forall n \geq 0. \quad (5.11)$$

Decimos que la sucesión es una *submartingala* si

$$E(X_{n+1}|\mathcal{F}_n) \geq X_n \quad c.s. \quad \forall n \geq 0. \quad (5.12)$$

y una *supermartingala* si

$$E(X_{n+1}|\mathcal{F}_n) \leq X_n \quad c.s. \quad \forall n \geq 0. \quad (5.13)$$

Decimos que es una  $L^p$ -martingala si además  $E|X_n|^p < \infty$  para todo  $n$ . Decimos que es  $L^p$ -acotada si además  $\sup_n E|X_n|^p < \infty$ .

### Observación 5.2

1.  $\{X_n\}$  es una martingala si es a la vez una submartingala y una supermartingala.  $\{X_n\}$  es una supermartingala sii  $\{-X_n\}$  es una submartingala.
2. La relación (5.11) vale sii

$$\int_{\Lambda} X_{n+1} = \int_{\Lambda} X_n, \quad \forall \Lambda \in \mathcal{F}_n.$$

Un comentario similar vale para sub y supermartingalas.

3. Podemos reemplazar la condición (5.11) por

$$E(X_n|\mathcal{F}_m) = X_m \quad c.s. \quad \text{para cualesquiera } 0 \leq m < n. \quad (5.14)$$

Para ver esto basta usar repetidamente el lema de suavizamiento:

$$\begin{aligned} E(X_n|\mathcal{F}_m) &= E(E(X_n|\mathcal{F}_{n-1})|\mathcal{F}_m) \\ &= E(X_{n-1}|\mathcal{F}_m) = E(E(X_{n-1}|\mathcal{F}_{n-2})|\mathcal{F}_m) \\ &= E(X_{n-2}|\mathcal{F}_m) = \cdots = E(X_{m+1}|\mathcal{F}_m) = X_m \end{aligned}$$

4. Si  $(X_n)$  es una martingala entonces  $E(X_n)$  es constante. En el caso de una submartingala, la media crece mientras que para una submartingala, decrece. Por ejemplo, para martingalas,

$$E(X_m) = E(E(X_n|\mathcal{F}_m)) = E(X_n).$$

5. Sea  $\{X_n, \mathcal{F}_n, n \geq 0\}$  una (sub, super) martingala, y sea  $\mathcal{G}_n = \sigma(X_0, X_1, \dots, X_n)$ . Entonces  $\{X_n, \mathcal{G}_n, n \geq 0\}$  también es una (sub, super) martingala.

Para ver por qué es cierto esto observamos que como  $X_n \in \mathcal{F}_n$ , se tiene que  $\mathcal{G}_n = \sigma(X_0, \dots, X_n) \subset \mathcal{F}_n$ , y por suavizamiento

$$E(X_{n+1}|\mathcal{G}_n) = E(E(X_{n+1}|\mathcal{F}_n)|\mathcal{G}_n) = E(X_n|\mathcal{G}_n) = X_n.$$

**Definición 5.13** Una sucesión integrable  $\{U_n\}$  adaptada a  $\{\mathcal{F}_n\}$  es una *sucesión de diferencias de martingala* si

$$E(U_{n+1}|\mathcal{F}_n) = 0 \quad \forall n \geq 0. \quad (5.15)$$

$\{U_n\}$  es una *sucesión de diferencias de submartingala (supermartingala)* si

$$E(U_{n+1}|\mathcal{F}_n) \geq (\leq) 0 \quad \forall n \geq 0. \quad (5.16)$$

**Teorema 5.7** Sea  $\{U_n\}$  integrable y adaptada a  $\{\mathcal{F}_n\}$  y sea  $X_n = \sum_{k=0}^n U_k$ ,  $n \geq 0$ .

- (i)  $\{(X_n, \mathcal{F}_n), n \geq 0\}$  es una martingala sii  $\{(U_n, \mathcal{F}_n), n \geq 0\}$  es una sucesión de diferencias de martingala, una submartingala sii  $\{(U_n, \mathcal{F}_n), n \geq 0\}$  es una sucesión de diferencias de submartingala, y una supermartingala sii  $\{(U_n, \mathcal{F}_n), n \geq 0\}$  es una sucesión de diferencias de supermartingala.
- (ii) Una sucesión de diferencias de martingala tiene esperanza constante 0, una sucesión de diferencias de submartingala tiene esperanza no-negativa, y una sucesión de diferencias de martingala tiene esperanza no-positiva.

### 5.4.1. Ejemplos.

#### Ejemplo 5.6

Sea  $\{Y_n, n \geq 1\}$  una sucesión de v.a.i. con media 0 y sea  $X_n = \sum_{k=1}^n Y_k$ ,  $n \geq 1$  con  $Y_0 = X_0 = 0$ . Sea

$$\mathcal{F}_n = \sigma(Y_0, Y_1, \dots, Y_n) = \sigma(X_0, X_1, \dots, X_n), \quad n \geq 0.$$

Entonces  $\{(X_n, \mathcal{F}_n), n \geq 1\}$  es una martingala y  $\{(Y_n, \mathcal{F}_n), n \geq 1\}$  es una sucesión de diferencias de martingala:

$$E(X_{n+1}|\mathcal{F}_n) = E(X_n + Y_{n+1}|\mathcal{F}_n) = X_n + E(Y_{n+1}|\mathcal{F}_n) = X_n \quad c.s.$$

#### Ejemplo 5.7

Sean  $X \in L^1$  y  $\{\mathcal{F}_n, n \geq 0\}$  una filtración. Para  $n \geq 0$  definimos

$$X_n = E(X|\mathcal{F}_n)$$

Entonces  $\{(X_n, \mathcal{F}_n), n \geq 1\}$  es una martingala:

$$E(X_{n+1}|\mathcal{F}_n) = E(E(X|\mathcal{F}_{n+1})|\mathcal{F}_n) = E(X|\mathcal{F}_n) = X_n.$$

#### Ejemplo 5.8

Sea  $\{Y_n, n \geq 1\}$  v.a.i. con  $EY_k = \mu_k$ ,  $\text{Var}(Y_k) = \sigma_k^2$  y ponemos  $s_n^2 = \sum_{k=1}^n \sigma_k^2$  para  $n \geq 1$ . Tomamos  $\{\mathcal{F}_n, n \geq 1\}$  la filtración natural. Finalmente ponemos

$$X_n = \left( \sum_{k=1}^n (Y_k - \mu_k) \right)^2 - s_n^2, \quad n \geq 1.$$

Entonces  $\{(X_n, \mathcal{F}_n), n \geq 1\}$  es una martingala.

Para ver esto podemos suponer, sin pérdida de generalidad, que todas las medias valen 0. tenemos

$$\begin{aligned} E(X_{n+1}|\mathcal{F}_n) &= E\left(\left(\sum_{k=1}^n Y_k + Y_{n+1}\right)^2 - s_{n+1}^2|\mathcal{F}_n\right) \\ &= E\left(\left(\sum_{k=1}^n Y_k\right)^2|\mathcal{F}_n\right) + E(Y_{n+1}^2|\mathcal{F}_n) + 2E\left(\left(\sum_{k=1}^n Y_k\right)Y_{n+1}|\mathcal{F}_n\right) - s_{n+1}^2 \\ &= \left(\sum_{k=1}^n Y_k\right)^2 + \sigma_{n+1}^2 + 2\left(\sum_{k=1}^n Y_k\right)E(Y_{n+1}|\mathcal{F}_n) - s_n^2 - \sigma_{n+1}^2 \\ &= X_n + 2\left(\sum_{k=1}^n Y_k\right) \cdot 0 = X_n. \end{aligned}$$

En particular, si  $Y_1, Y_2, \dots$  son i.i.d. centradas, entonces  $\{X_n = (\sum_{k=1}^n Y_k)^2 - n\sigma_1^2, n \geq 1\}$  es una martingala.

### Ejemplo 5.9

Sea  $\{Y_n, n \geq 1\}$  una sucesión de v.a.i. con media 1 y definimos  $X_n = \prod_{k=1}^n Y_k, n \geq 1$ , con  $Y_0 = X_0 = 1$  y sea  $\{\mathcal{F}_n, n \geq 1\}$  la filtración natural. Entonces  $\{(X_n, \mathcal{F}_n), n \geq 0\}$  es una martingala porque

$$E(X_{n+1}|\mathcal{F}_n) = E(X_n \cdot Y_{n+1}|\mathcal{F}_n) = X_n \cdot E(Y_{n+1}|\mathcal{F}_n) = X_n \cdot 1 = X_n.$$

### Ejemplo 5.10

Sea  $X_0 = 1$  y para  $n \geq 1$  definimos recursivamente

$$X_{n+1} = \begin{cases} 2X_n, & \text{con probabilidad } 1/2, \\ 0, & \text{con probabilidad } 1/2, \end{cases}$$

o equivalentemente

$$P(X_n = 2^n) = \frac{1}{2^n}, \quad P(X_n = 0) = 1 - \frac{1}{2^n}.$$

Como

$$X_n = \prod_{k=1}^n Y_k,$$

donde  $Y_1, Y_2, \dots$  son i.i.d. que valen 0 ó 2 con probabilidad 1/2,  $X_n$  es el producto de variables i.i.d. con media 1, y por el ejemplo anterior es una martingala.

### Ejemplo 5.11

Sea  $\{Y_n, n \geq 1\}$  una sucesión de v.a.i.i.d. con función generadora de momentos  $\psi$  finita, y sea  $S_n = \sum_{k=1}^n Y_k, n \geq 1$ . Entonces

$$X_n = \frac{e^{tS_n}}{(\psi(t))^n} = \prod_{k=1}^n \frac{e^{tY_k}}{\psi(t)}, \quad n \geq 1,$$

para  $t$  dentro del rango de convergencia de la f.g.m., es una martingala que se conoce como la martingala exponencial. Esto es consecuencia del ejemplo 5.9, porque  $X_n$  es el producto de  $n$  factores independientes con media 1.

### Ejemplo 5.12

Si  $\{Y_n, n \geq 1\}$  son variables independientes con densidad común  $f$ , la sucesión de cocientes de verosimilitudes es

$$L_n = \prod_{k=1}^n \frac{f(Y_k; \theta_1)}{f(Y_k; \theta_0)}, \quad n \geq 0$$

donde  $\theta_0$  y  $\theta_1$  son los valores de algún parámetro bajo las hipótesis nula y alternativa, respectivamente. Esta sucesión es una martingala como la del ejemplo 5.9 bajo la hipótesis nula:

$$\mathbb{E} \left( \frac{f(Y_k; \theta_1)}{f(Y_k; \theta_0)} \right) = \int_{-\infty}^{\infty} \frac{f(y; \theta_1)}{f(y; \theta_0)} f(y; \theta_0) dy = \int_{-\infty}^{\infty} f(y; \theta_1) dy = 1.$$

### Ejemplo 5.13

Sea  $\{(X_n, \mathcal{F}_n), n \geq 0\}$  una martingala y  $\{U_n, n \geq 0\}$  la sucesión de diferencias de martingala asociada. Sea  $\{v_k, k \geq 0\}$  una sucesión predecible, ponemos  $X_0 = 0$  y

$$X_n = \sum_{k=1}^n U_k v_k, \quad n \geq 1.$$

Una sucesión de este tipo se conoce como una transformada de martingala y es a su vez una martingala:

$$\begin{aligned} \mathbb{E}(X_{n+1} | \mathcal{F}_n) &= \sum_{k=1}^n \mathbb{E}(U_k v_k | \mathcal{F}_n) + \mathbb{E}(U_{n+1} v_{n+1} | \mathcal{F}_n) \\ &= X_n + v_{n+1} \mathbb{E}(U_{n+1} | \mathcal{F}_n) = X_n. \end{aligned}$$

### Ejemplo 5.14

Cualquier sucesión integrable y adaptada puede 'ajustarse' para transformarla en una martingala. Sea  $\{Y_n, n \geq 0\}$  una sucesión adaptada a  $\{\mathcal{F}_n\}$  y pongamos  $X_0 = Y_0$  y

$$X_n = \sum_{k=1}^n (Y_k - \mathbb{E}(Y_k | \mathcal{F}_{k-1})), \quad n \geq 1.$$

Por el lema de suavizamiento y el hecho de que  $Y_k \in \mathcal{F}_n$  para  $1 \leq k \leq n$ ,

$$\begin{aligned} \mathbb{E}(X_{n+1} | \mathcal{F}_n) &= \mathbb{E} \left( \sum_{k=1}^{n+1} (Y_k - \mathbb{E}(Y_k | \mathcal{F}_{k-1})) | \mathcal{F}_n \right) \\ &= \sum_{k=1}^n \mathbb{E} (Y_k - \mathbb{E}(Y_k | \mathcal{F}_{k-1}) | \mathcal{F}_n) + \mathbb{E} (Y_{n+1} - \mathbb{E}(Y_{n+1} | \mathcal{F}_n) | \mathcal{F}_n) \\ &= \sum_{k=1}^n (Y_k - \mathbb{E}(Y_k | \mathcal{F}_{k-1})) + \mathbb{E}(Y_{n+1} | \mathcal{F}_n) - \mathbb{E}(Y_{n+1} | \mathcal{F}_n) \\ &= X_n \end{aligned}$$

de modo que  $\{(X_n, \mathcal{F}_n), n \geq 1\}$  es una martingala.

Como corolario obtenemos que las sumas parciales de cualquier sucesión integrable y adaptada puede descomponerse como la suma de una martingala mas la suma de las esperanzas condicionales:

$$\sum_{k=1}^n Y_k = X_n + \sum_{k=1}^n \mathbb{E}(Y_k | \mathcal{F}_{k-1}), \quad n \geq 1.$$

Si las variables  $\{Y_n, n \geq 1\}$  son independientes con  $\mathbb{E} Y_k = \mu_k$ , las esperanzas condicionales se convierten en esperanzas ordinarias y la descomposición se reduce a

$$\sum_{k=1}^n Y_k = \sum_{k=1}^n (Y_k - \mu_k) + \sum_{k=1}^n \mu_k, \quad n \geq 1.$$

**Ejemplo 5.15**

Sea  $\{Y_n, n \geq 0\}$  una cadena de Markov con los enteros como espacio de estados y matriz de transición  $P = (P_{ij})$ . Sea  $f$  un eigenvector con eigenvalor asociado  $\lambda$  es decir,

$$Pf = \lambda f$$

o en términos de las componentes

$$\sum_j P_{ij} f(j) = \lambda f(i).$$

En términos de esperanzas tenemos

$$E(f(Y_{n+1})|Y_n = i) = \lambda f(i)$$

o

$$E(f(Y_{n+1})|Y_n) = \lambda f(Y_n)$$

y por la propiedad de Markov esto es

$$E(f(Y_{n+1})|Y_n) = E(f(Y_{n+1})|Y_0, Y_1, \dots, Y_n) = \lambda f(Y_n)$$

por lo tanto  $(\lambda^{-n} f(Y_n), \sigma(Y_0, \dots, Y_n))$  para  $n \geq 1$  es una martingala.

Un caso particular es el proceso de ramificación simple. Supongamos que  $\{p_k, k \geq 0\}$  es la distribución de la descendencia, de modo que  $p_k$  es la probabilidad de que un individuo de la población tenga  $k$  descendientes. Sea  $m = \sum_k k p_k$  el promedio de descendientes por individuo. Sea  $\{Z^{(n)}(i), n \geq 0, i \geq 1\}$  una sucesión i.i.d. con función de probabilidad común  $\{p_k\}$  y definimos de manera recursiva  $Z_0 = 1$  y

$$Z_{n+1} = \begin{cases} Z^{(n)}(1) + \dots + Z^{(n)}(Z_n), & \text{si } Z_n > 0, \\ 0, & \text{si } Z_n = 0, \end{cases}$$

que representa el número de individuos en la generación  $n + 1$ . Entonces  $Z_n$  es una cadena de Markov y

$$P_{ij} = P(Z_{n+1} = j | Z_n = i) = \begin{cases} \delta_{0j}, & \text{si } i = 0, \\ p_j^{*i}, & \text{si } i \geq 1, \end{cases}$$

donde, para  $i \geq 1$ ,  $p_j^{*i}$  es la  $j$ -ésima componente de la  $i$ -ésima convolución de la sucesión  $\{p_k\}$ . Observamos que para  $i \geq 1$ ,

$$\sum_{j=0}^{\infty} P_{ij} j = \sum_{j=1}^{\infty} p_j^{*i} j = im$$

mientras que para  $i = 0$

$$\sum_{j=0}^{\infty} P_{ij} j = P_{00} \cdot 0 + 0 = 0 = im$$

Con  $f(j) = j$  tenemos que  $Pf = mf$  y por lo tanto el proceso  $(m^{-n} Z_n, \sigma(Z_0, \dots, Z_n))$  para  $n \geq 0$  es una martingala.

La siguiente proposición da algunos mecanismos para obtener nuevas martingalas a partir de ejemplos conocidos.

**Proposición 5.5** Sean  $a, b \in \mathbb{R}$  y  $\{(X_n^{(i)}, \mathcal{F}_n), n \geq 0\}$  para  $i = 1, 2$  martingalas. Entonces

- (1)  $\{(aX_n^{(1)} + bX_n^{(2)}, \mathcal{F}_n), n \geq 0\}$  es una martingala.
- (2)  $\{(\max\{X_n^{(1)}, X_n^{(2)}\}, \mathcal{F}_n), n \geq 0\}$  es una submartingala.
- (2)  $\{(\min\{X_n^{(1)}, X_n^{(2)}\}, \mathcal{F}_n), n \geq 0\}$  es una supermartingala.

**Demostración.** (1) es consecuencia de la linealidad de las esperanzas condicionales. Para ver (2), teniendo en cuenta que  $\max\{X_n^{(1)}, X_n^{(2)}\} \geq X_n^{(1)}$  y  $\max\{X_n^{(1)}, X_n^{(2)}\} \geq X_n^{(2)}$  tenemos

$$E(\max\{X_{n+1}^{(1)}, X_{n+1}^{(2)}\} | \mathcal{F}_n) \geq \max\{E(X_{n+1}^{(1)} | \mathcal{F}_n), E(X_{n+1}^{(2)} | \mathcal{F}_n)\} = \max\{X_n^{(1)}, X_n^{(2)}\}$$

lo cual demuestra (2). Para ver (3) basta cambiar signos. ■

**Proposición 5.6** Si  $\{(X_n, \mathcal{F}_n), n \geq 0\}$  es

- (a) una martingala y  $g$  es una función convexa o
- (b) una submartingala y  $g$  es convexa no-decreciente,
- y además  $E|g(X_n)| < \infty$  para todo  $n$ , entonces  $\{(g(X_n), \mathcal{F}_n), n \geq 0\}$  es una submartingala.

**Demostración.** Sea  $\{(X_n, \mathcal{F}_n), n \geq 0\}$  una martingala. Por convexidad

$$E(g(X_{n+1}) | \mathcal{F}_n) \geq g(E(X_{n+1} | \mathcal{F}_n)) = g(X_n).$$

Para submartingalas la primera desigualdad es igual pero como  $E(X_{n+1} | \mathcal{F}_n) \geq X_n$  la segunda igualdad se convierte en una desigualdad  $\geq$  si  $g$  es no-decreciente. ■

**Teorema 5.8** (a) Si  $\{(X_n, \mathcal{F}_n), n \geq 1\}$  es una martingala, entonces  $\{(X_n^+, \mathcal{F}_n), n \geq 1\}$ ,  $\{(X_n^-, \mathcal{F}_n), n \geq 1\}$  y  $\{(|X_n|, \mathcal{F}_n), n \geq 1\}$  son submartingalas.

(b) Si  $\{(X_n, \mathcal{F}_n), n \geq 1\}$  es una martingala y  $E|X_n|^p < \infty$  para todo  $n$  y algún  $p > 1$ , entonces  $\{(|X_n|^p, \mathcal{F}_n), n \geq 1\}$  es una submartingala.

(c) Si  $\{(X_n, \mathcal{F}_n), n \geq 1\}$  es una submartingala, también lo es  $\{(X_n^+, \mathcal{F}_n), n \geq 1\}$

(d) Si  $\{(X_n, \mathcal{F}_n), n \geq 1\}$  es una submartingala no-negativa y  $E|X_n|^p < \infty$  para todo  $n$  y algún  $p \geq 1$  entonces  $\{(|X_n|^p, \mathcal{F}_n), n \geq 1\}$  es una submartingala.

## 5.5. Ortogonalidad

**Lema 5.2** Sea  $\{(X_n, \mathcal{F}_n), n \geq 0\}$  una martingala en  $L^2$  con sucesión de diferencias de martingala  $\{U_n\}$ .

(a) Se tiene

$$E(U_m U_n) = \begin{cases} E(U_m^2), & \text{para } n = m, \\ 0, & \text{en otro caso.} \end{cases}$$

(b) Para  $m < n$

$$\begin{aligned} E(U_n X_m) &= E(U_n E(X_n | \mathcal{F}_m)) = 0, \\ E(X_n X_m) &= E(X_m E(X_n | \mathcal{F}_m)) = E(X_m^2), \\ E(X_n - X_m)^2 &= E(X_n^2) - E(X_m^2), \\ E\left(\sum_{k=m+1}^n U_k\right)^2 &= \sum_{k=m+1}^n E(U_k^2). \end{aligned}$$

(c) Si  $\{(X_n, \mathcal{F}_n), n \geq 0\}$  es una submartingala (super martingala) en  $L^2$ , las mismas relaciones valen con = reemplazado por  $\geq$  ( $\leq$ ).

**Demostración.** La herramienta fundamental es el lema de suavizamiento.

(a) El resultado es inmediato en el caso  $m = n$ . Si  $m < n$ ,

$$E(U_n U_m) = E(E(U_n U_m | \mathcal{F}_m)) = E(U_m E(U_n | \mathcal{F}_m)) = E(X_m \cdot 0) = 0.$$

(b) De manera similar,

$$\begin{aligned} E(U_n X_m) &= E(E(U_n X_m | \mathcal{F}_m)) = E(X_m E(U_n | \mathcal{F}_m)) = E(X_m \cdot 0) = 0, \\ E(X_n X_m) &= E(E(X_n X_m | \mathcal{F}_m)) = E(X_m E(X_n | \mathcal{F}_m)) = E(X_m^2). \end{aligned}$$

Usando este último resultado y

$$E(X_n - X_m)^2 = E(X_n^2) - 2E(X_n X_m) + E(X_m^2) = E(X_n^2) - E(X_m^2)$$

La última igualdad es una consecuencia de este resultado.

(c) Sigue de los resultados anteriores. ■

**Observación 5.3** Para martingalas se puede reescribir la tercera relación de (b) como

$$E(X_n^2) = E(X_m^2) + E(X_n - X_m)^2$$

que muestra que las martingalas tienen incrementos ortogonales, y además que  $E(X_n^2) \geq E(X_m^2)$ .

## 5.6. Descomposiciones

**Teorema 5.9 (Descomposición de Doob)** *Toda submartingala  $\{(X_n, \mathcal{F}_n), n \geq 0\}$  puede descomponerse de manera única en la suma de una martingala  $\{(M_n, \mathcal{F}_n), n \geq 0\}$  y un proceso creciente  $\{(A_n, \mathcal{F}_n), n \geq 0\}$ :*

$$X_n = M_n + A_n, \quad n \geq 0.$$

**Demostración.** Recordemos el ejemplo 5.14. Ponemos  $M_0 = X_0$  de modo que  $A_0 = X_0 - M_0 = 0$  y

$$M_n = \sum_{k=1}^n (X_k - E(X_k | \mathcal{F}_{k-1})), \quad \text{y} \quad A_n = X_n - M_n,$$

de modo que  $\{(M_n, \mathcal{F}_n), n \geq 0\}$  es una martingala. Falta ver que  $\{(A_n, \mathcal{F}_n), n \geq 0\}$  es un proceso creciente, y ya sabemos que  $A_0 = 0$ . Además, el proceso  $A_n$  es predecible:

$$A_n = \sum_{k=1}^n E(X_k | \mathcal{F}_{k-1}) - \sum_{k=1}^{n-1} X_k \in \mathcal{F}_{n-1}.$$

Finalmente,

$$\begin{aligned} A_{n+1} - A_n &= X_{n+1} - M_{n+1} - X_n + M_n = (X_{n+1} - X_n) - (M_{n+1} - M_n) \\ &= X_{n+1} - X_n - (X_{n+1} - E(X_{n+1} | \mathcal{F}_n)) \\ &= E(X_{n+1} | \mathcal{F}_n) - X_n \geq 0, \end{aligned}$$

por la definición de submartingala. Esto establece la existencia de la descomposición y falta ver que es única.

Supongamos que  $X_n = M'_n + A'_n$  es otra descomposición. Como  $A_n$  es predecible,

$$\begin{aligned} A'_{n+1} - A'_n &= E(A'_{n+1} - A'_n | \mathcal{F}_n) = E((X_{n+1} - X_n) - (M'_{n+1} - M'_n) | \mathcal{F}_n) \\ &= E(X_{n+1} | \mathcal{F}_n) - X_n - (M'_n - M'_n) = E(X_{n+1} | \mathcal{F}_n) - X_n \\ &= A_{n+1} - A_n, \end{aligned}$$

y como  $A_0 = A'_0 = 0$  esto demuestra la unicidad del proceso creciente. Pero

$$M_n = X_n - A_n = X_n - A'_n = M'_n,$$

y por lo tanto la martingala también es única. ■

**Corolario 5.3** *Sea  $\{X_n, n \geq 0\}$  una supermartingala. Existen una martingala  $\{M_n, n \geq 0\}$  y un proceso decreciente  $\{A_n, n \geq 0\}$  tales que*

$$X_n = M_n + A_n,$$

con  $A_0 = 0$ . Esta descomposición es única.

**Ejemplo 5.16**

Sea  $\{(X_n, \mathcal{F}_n), n \geq 0\}$  una martingala en  $L^2$ , entonces  $\{(X_n^2, \mathcal{F}_n), n \geq 0\}$  es una submartingala. Para ver esto basta tener en cuenta que  $f(x) = x^2$  es una función convexa y la desigualdad de Jensen. Veamos cuál es su descomposición de Doob.

Ponemos  $M_0 = X_0^2$  y

$$M_n = \sum_{k=1}^n (X_k^2 - \mathbb{E}(X_k^2 | \mathcal{F}_{k-1})), \quad y \quad A_n = X_n^2 - M_n,$$

Sea  $\{U_n, n \geq 0\}$  la sucesión de diferencias de martingala asociada a la martingala  $\{X_n\}$ . Sabemos que esta sucesión es centrada. Tenemos

$$X_k^2 = (X_{k-1} + U_k)^2 = X_{k-1}^2 + 2X_{k-1}U_k + U_k^2$$

y en consecuencia

$$\mathbb{E}(X_k^2 | \mathcal{F}_{k-1}) = X_{k-1}^2 + 2X_{k-1} \mathbb{E}(U_k | \mathcal{F}_{k-1}) + \mathbb{E}(U_k^2 | \mathcal{F}_{k-1}),$$

pero  $\mathbb{E}(U_k | \mathcal{F}_{k-1}) = 0$  y entonces

$$\mathbb{E}(X_k^2 | \mathcal{F}_{k-1}) = X_{k-1}^2 + \mathbb{E}(U_k^2 | \mathcal{F}_{k-1}).$$

Ahora

$$\begin{aligned} A_{n+1} - A_n &= X_{n+1}^2 - X_n^2 - M_{n+1} + M_n = \mathbb{E}(X_{n+1}^2 | \mathcal{F}_n) - X_n^2 \\ &= X_n^2 + \mathbb{E}(U_{n+1}^2 | \mathcal{F}_n) - X_n^2 \\ &= \mathbb{E}(U_{n+1}^2 | \mathcal{F}_n), \end{aligned}$$

y por lo tanto la descomposición de Doob para  $X_n^2$  es

$$M_n = X_n^2 - \sum_{k=1}^n \mathbb{E}(U_k^2 | \mathcal{F}_{k-1}), \quad A_n = \sum_{k=1}^n \mathbb{E}(U_k^2 | \mathcal{F}_{k-1})$$

El siguiente resultado, que presenta la descomposición de Krickeberg, lo enunciamos sin demostración, que puede verse en el libro *Probability. A Graduate Course* de A. Gut, p. 490.

**Teorema 5.10 (Descomposición de Krickeberg)** (a) Para cualquier martingala  $\{(X_n, \mathcal{F}_n), n \geq 0\}$  con  $\sup_n \mathbb{E}(X_n^+) < \infty$ , existen dos martingalas no-negativas  $\{(M_n^{(i)}, \mathcal{F}_n), n \geq 0\}$ ,  $i = 1, 2$  tales que

$$X_n = M_n^{(1)} - M_n^{(2)}.$$

(b) Para cualquier submartingala  $\{(X_n, \mathcal{F}_n), n \geq 0\}$  con  $\sup_n \mathbb{E}(X_n^+) < \infty$ , existen dos martingalas no-negativas  $\{(M_n^{(i)}, \mathcal{F}_n), n \geq 0\}$ ,  $i = 1, 2$  y un proceso creciente  $\{(A - n, \mathcal{F}_n), n \geq 0\}$  tales que

$$X_n = M_n^{(1)} - M_n^{(2)} + A_n.$$

## 5.7. Tiempos de Paro

**Definición 5.14** Una v.a.  $T : \Omega \rightarrow \bar{\mathbb{N}} = \mathbb{N} \cup \{+\infty\}$  es un tiempo de paro si  $\{T \leq n\} \in \mathcal{F}_n$  para todo  $n$ .

Una v.a. constante con valor entero o  $+\infty$  es un tiempo de paro. Podemos pensar que los tiempos de paro son el instante en el cual ocurre un evento aleatorio, con la convención de que toma el valor  $+\infty$  si

el evento nunca ocurre. Por ejemplo, supongamos que  $(X_n)_{n \geq 0}$  es una martingala y nos interesa el primer instante en el cual vale al menos 12. Este instante es aleatorio y lo podemos describir como

$$T = \begin{cases} \inf_{n \geq 0} \{n : X_n \geq 12\} & \text{si } X_n \geq 12 \text{ para algún } n \in \mathbb{N}, \\ +\infty & \text{si no.} \end{cases}$$

Es decir,

$$T(\omega) = \inf_{n \geq 0} \{n : X_n(\omega) \geq 12\}$$

si  $X_n(\omega) \geq 12$  para algún  $n \in \mathbb{N}$  y  $T(\omega) = +\infty$  si no. Observamos que el evento  $\{\omega : T(\omega) \leq n\}$  se puede expresar como

$$\{T \leq n\} = \bigcup_{k=0}^n \{X_k \geq 12\} \in \mathcal{F}_n$$

porque  $\{X_k \geq 12\} \in \mathcal{F}_k \subset \mathcal{F}_n$  si  $k \leq n$ .

Un tiempo de paro es *acotado* si existe una constante  $c$  tal que  $P(T \leq c) = 1$ . Si  $T$  es un tiempo de paro finito denotamos por  $X_T$  a la variable

$$X_T(\omega) = X_{T(\omega)}(\omega),$$

es decir, toma el valor  $X_n$  siempre que  $T = n$ .

**Teorema 5.11** *Sea  $T$  un tiempo de paro acotado por  $c$  y sea  $\{X_n, n \geq 0\}$  una martingala. Entonces  $E(X_T) = E(X_0)$ .*

**Demostración.** Partimos de  $X_T(\omega) = \sum_{n=0}^{\infty} X_n(\omega) \mathbf{1}_{\{T(\omega)=n\}}$ . Por lo tanto, suponiendo sin pérdida de generalidad que  $c$  es entero,

$$E(X_T) = E \left[ \sum_{k=0}^{\infty} X_k \mathbf{1}_{\{T=k\}} \right] = E \left[ \sum_{k=0}^c X_k \mathbf{1}_{\{T=k\}} \right] = \sum_{k=0}^c E [X_k \mathbf{1}_{\{T=k\}}].$$

Como  $\{T = n\} = \{T \leq n\} \setminus \{T \leq n-1\}$  vemos que  $\{T = n\} \in \mathcal{F}_n$ , y obtenemos que la expresión anterior es

$$\begin{aligned} &= \sum_{k=0}^c E [E[X_k | \mathcal{F}_n] \mathbf{1}_{\{T=k\}}] = \sum_{k=0}^c E [X_k \mathbf{1}_{\{T=k\}}] \\ &= E \left[ X_c \sum_{n=0}^c \mathbf{1}_{\{T=n\}} \right] = E(X_c) = E(X_0). \end{aligned}$$

■

**Teorema 5.12** *Sea  $T$  un tiempo de paro acotado por  $c \in \mathbb{N}$  y sea  $\{X_n, n \geq 0\}$  una submartingala. Entonces  $E(X_T) \leq E(X_0)$ .*

**Demostración.** Es similar a la del teorema 5.11 y queda como ejercicio. ■

**Definición 5.15** Sea  $T$  un tiempo de paro. Definimos la  $\sigma$ -álgebra  $\mathcal{F}_T$  como

$$\mathcal{F}_T = \{A \in \mathcal{F} : A \cap \{T \leq n\} \in \mathcal{F}_n, \text{ para todo } n\}$$

**Teorema 5.13** *Si  $T$  es un tiempo de paro,  $\mathcal{F}_T$  es una  $\sigma$ -álgebra.*

**Demostración.** Claramente  $\emptyset$  y  $\Omega$  están en  $\mathcal{F}_T$ . Si  $A \in \mathcal{F}_T$  entonces

$$A^c \cap \{T \leq n\} = \{T \leq n\} \setminus (A \cap \{T \leq n\}),$$

y por lo tanto  $A^c \in \mathcal{F}_T$ . Además si  $(A_i)_{i \geq 1}$  están en  $\mathcal{F}_T$ , entonces

$$(\cup_{i \geq 1} A_i) \cap \{T \leq n\} = \cup_{i \geq 1} (A_i \cap \{T \leq n\}) \in \mathcal{F}_n,$$

de modo que  $\mathcal{F}_T$  es cerrada bajo complementos y uniones numerables, y por lo tanto es una  $\sigma$ -álgebra. ■

**Teorema 5.14** Sean  $S, T$  tiempos de paro, con  $S \leq T$ . Entonces  $\mathcal{F}_S \subset \mathcal{F}_T$ .

**Demostración.** Como  $S \leq T$  tenemos  $\{T \leq n\} \subset \{S \leq n\}$ . Por lo tanto si  $A \in \mathcal{F}_S$  se tiene

$$A \cap \{T \leq n\} = A \cap \{S \leq n\} \cap \{T \leq n\}$$

pero  $A \cap \{S \leq n\} \in \mathcal{F}_n$  y  $\{T \leq n\} \in \mathcal{F}_n$  de modo que  $A \cap \{T \leq n\} \in \mathcal{F}_n$  y en consecuencia  $A \in \mathcal{F}_T$ . ■

Sea ahora  $\{X_n, n \geq 1\}$  una sucesión de v.a. adaptada a la filtración  $\{\mathcal{F}_n\}$ . Sea  $T$  un tiempo de paro con  $P(T < \infty) = 1$ . Entonces  $X_T = \sum_{n \geq 0} X_n \mathbf{1}_{\{T=n\}}$ , y tenemos el siguiente resultado:

**Teorema 5.15**  $X_T$  es  $\mathcal{F}_T$ -medible.

**Demostración.** Sea  $\Lambda \in \mathcal{B}$ , queremos mostrar que  $\{X_T \in \Lambda\} \in \mathcal{F}_T$ , es decir, tenemos que ver que  $\{X_T \in \Lambda\} \cap \{T \leq n\} \in \mathcal{F}_n$ . Pero

$$\{X_T \in \Lambda\} \cap \{T \leq n\} = \bigcup_{k=0}^n \{X_T \in \Lambda\} \cap \{T = k\} = \bigcup_{k=0}^n \{X_k \in \Lambda\} \cap \{T = k\},$$

y  $\{X_k \in \Lambda\} \cap \{T = k\} \in \mathcal{F}_k \subset \mathcal{F}_n$  para  $k \leq n$ . ■

**Teorema 5.16 (Teorema de Muestreo Opcional de Doob)** Sea  $\{X_n, n \geq 0\}$  una martingala y sean  $S, T$  tiempos de paro acotados por una constante  $c$ , con  $S \leq T$  c.s. Entonces

$$E(X_T | \mathcal{F}_S) = X_S \quad \text{c.s.}$$

**Demostración.** En primer lugar  $|X_T| \leq \sum_{n=0}^c |X_n|$  es integrable, y lo mismo ocurre para  $X_S$ , y además  $X_S$  es  $\mathcal{F}_S$ -medible por el teorema anterior. Falta demostrar que para todo  $A \in \mathcal{F}_S$

$$E(X_S \mathbf{1}_A) = \int_A X_T dP = \int_A X_S dP = E(X_T \mathbf{1}_A)$$

Definimos una nueva variable aleatoria  $R$  por

$$R(\omega) = S(\omega) \mathbf{1}_A(\omega) + T(\omega) \mathbf{1}_{A^c}(\omega).$$

Entonces  $R$  también es un tiempo de paro:

$$\{R \leq n\} = (A \cap \{S \leq n\}) \cup (A^c \cap \{T \leq n\}),$$

y  $A \cap \{S \leq n\} \in \mathcal{F}_n$  porque  $A \in \mathcal{F}_S$ . Como  $A \in \mathcal{F}_S$  tenemos  $A^c \in \mathcal{F}_S \subset \mathcal{F}_T$ . En consecuencia  $A^c \cap \{T \leq n\} \in \mathcal{F}_n$  y concluimos que  $\{R \leq n\} \in \mathcal{F}_n$  y  $R$  es un tiempo de paro. Por lo tanto  $E(X_R) = E(X_T) = E(X_0)$ . Pero

$$E(X_R) = E(X_S \mathbf{1}_A + X_T \mathbf{1}_{A^c}),$$

$$E(X_T) = E(X_T \mathbf{1}_A + X_T \mathbf{1}_{A^c}),$$

restando obtenemos

$$E(X_S \mathbf{1}_A) - E(X_T \mathbf{1}_A) = 0.$$

■

**Teorema 5.17** Sea  $\{X_n, n \geq 0\}$  una sucesión de v.a. adaptada a la filtración  $\{\mathcal{F}_n, n \geq 0\}$ . Supongamos que  $E|X_n| < \infty$  para todo  $n$  y  $E(X_T) = E(X_0)$  para todo tiempo de paro acotado  $T$ . Entonces  $X$  es una martingala.

**Demostración.** Sea  $0 \leq m < n < \infty$ , y sea  $A \in \mathcal{F}_m$ . Definimos un tiempo aleatorio por

$$T(\omega) = \begin{cases} m & \text{si } \omega \in A^c, \\ n & \text{si } \omega \in A. \end{cases}$$

Entonces  $T$  es un tiempo de paro, de modo que

$$E(X_0) = E(X_T) = E(X_m \mathbf{1}_{A^c} + X_n \mathbf{1}_A).$$

Pero también  $E(X_0) = E(X_m \mathbf{1}_{A^c} + X_m \mathbf{1}_A)$ . Restando obtenemos  $E(X_n \mathbf{1}_A) = E(X_m \mathbf{1}_A)$  o equivalentemente  $E(X_n | \mathcal{F}_m) = X_m$  c.s. ■

## 5.8. Desigualdades.

Sea  $(\Omega, \mathcal{F}, P)$  un espacio de probabilidad y  $\{\mathcal{F}_n, n \geq 0\}$  una filtración. Sea  $\{X_n, n \geq 0\}$  una sucesión de v.a. integrables con  $X_n \in \mathcal{F}_n$ . Sea  $W_n = \sup_{j \leq n} |X_j|$ . Observamos que  $W_n \leq W_{n+1}$  y si  $X_n$  es una martingala,  $W_n$  es una submartingala ya que

$$E(W_n) \leq E \left[ \sum_{j=1}^n |X_j| \right] < \infty.$$

La desigualdad de Markov dice que, para  $\alpha > 0$ ,

$$P(W_n \geq \alpha) = E[\mathbf{1}_{\{W_n \geq \alpha\}}] \leq \frac{1}{\alpha} E(W_n).$$

En el caso de una martingala podemos reemplazar  $W_n$  por  $|X_n|$  en el lado derecho.

**Teorema 5.18 (Primera Desigualdad de Doob)** Sea  $\{X_n, n \geq 1\}$  una martingala o una submartingala positiva. Entonces

$$P(W_n \geq \alpha) \leq \frac{1}{\alpha} E(|X_n|).$$

**Demostración.** Sea  $T = \min\{j : |X_j| \geq \alpha\}$  con la convención de que el mínimo de un conjunto vacío es  $+\infty$ . Como  $g(x) = |x|$  es convexa y creciente en  $\mathbb{R}^+$ , tenemos que  $|X_n|$  es una submartingala. Teniendo en cuenta que

$$\{T \leq n\} = \{W_n \geq \alpha\}$$

tenemos

$$P(W_n \geq \alpha) \leq P(T \leq n) \leq E(\mathbf{1}_{\{T \leq n\}}) \leq E \left[ \frac{|X_T|}{\alpha} \mathbf{1}_{\{T \leq n\}} \right],$$

y como  $X_T = X_{T \wedge n}$  en  $\{T \leq n\}$ ,

$$P(W_n \geq \alpha) \leq \frac{1}{\alpha} E[|X_{T \wedge n}| \mathbf{1}_{\{T \leq n\}}] \leq \frac{1}{\alpha} E[|X_{T \wedge n}|] \leq \frac{1}{\alpha} E[|X_n|]$$

por el teorema 5.12. ■

**Lema 5.3** Sea  $X \geq 0$  una v.a.,  $p > 0$  y  $E[X^p] < \infty$ . Entonces

$$E[X^p] = \int_0^\infty p\lambda^{p-1} P(X > \lambda) d\lambda.$$

**Demostración.** Tenemos

$$\int_0^\infty p\lambda^{p-1}P(X > \lambda) d\lambda = \int_0^\infty p\lambda^{p-1}E(\mathbf{1}_{\{X>\lambda\}}) d\lambda,$$

y por el teorema de Fubini

$$= E\left[\int_0^\infty p\lambda^{p-1}\mathbf{1}_{\{X>\lambda\}} d\lambda\right] = E\left[\int_0^X p\lambda^{p-1} d\lambda\right] = E[X^p].$$

■

**Teorema 5.19 (Segunda Desigualdad de Doob)** *Sea  $\{X_n, n \geq 1\}$  una martingala o una submartingala positiva. Sea  $1 < p < \infty$ . Existe una constante  $c_p$  que depende únicamente de  $p$  tal que*

$$E[(W_n)^p] \leq c_p E[|X_n|^p].$$

**Demostración.** Daremos la demostración para el caso de una martingala. Como  $g(x) = |x|$  es convexa,  $|X_n|$  es una submartingala. Sea  $\alpha > 0$  y  $Y_n = X_n \mathbf{1}_{\{|X_n|>\alpha/2\}}$ . Para  $n$  fijo definimos

$$Z_j = E[Y_n | \mathcal{F}_j], \quad 0 \leq j \leq n.$$

Observamos que  $\{Z_j, 0 \leq j \leq n\}$  es una martingala (ver ejemplo 4.7) y además que  $W_n \leq Z_n^* + \frac{\alpha}{2}$  con  $Z_n^* = \max_{1 \leq j \leq n} |Z_j|$  ya que

$$\begin{aligned} |X_j| &= |E(X_n | \mathcal{F}_j)| = |E(X_n \mathbf{1}_{\{|X_n|>\alpha/2\}} + X_n \mathbf{1}_{\{|X_n|\leq\alpha/2\}} | \mathcal{F}_j)| \\ &= |E(Y_n + X_n \mathbf{1}_{\{|X_n|\leq\alpha/2\}} | \mathcal{F}_j)| \\ &\leq |E(Y_n | \mathcal{F}_j)| + \frac{\alpha}{2} = |Z_j| + \frac{\alpha}{2}. \end{aligned}$$

Por la primera desigualdad de Doob tenemos

$$P(W_n > \alpha) \leq P(Z_n^* > \frac{\alpha}{2}) \leq \frac{2}{\alpha} E(|Z_n|) \leq \frac{2}{\alpha} E(|Y_n|) = \frac{2}{\alpha} E[|X_n| \mathbf{1}_{\{|X_n|>\alpha/2\}}]$$

Por el lema 5.3 y usando el teorema de Fubini tenemos

$$\begin{aligned} E[W_n^p] &= \int_0^\infty p\lambda^{p-1}P(M_n > \lambda) d\lambda \\ &\leq \int_0^\infty 2p\lambda^{p-2} E[|X_n| \mathbf{1}_{\{|X_n|>\lambda/2\}}] d\lambda \\ &= E\left[\int_0^{2|X_n|} 2p\lambda^{p-2} d\lambda | X_n\right] \\ &= \frac{2^p p}{p-1} E[|X_n|^p]. \end{aligned}$$

■

En la demostración vimos que  $c_p \leq 2^p p / (p-1)$ . Es posible demostrar que  $c_p^{1/p} = p/(p-1)$ , lo que permite reescribir el teorema de la siguiente manera

**Teorema 5.20 (Doob)** *Sea  $\{X_n, n \geq 1\}$  una martingala o una submartingala positiva. Sea  $1 < p < \infty$ . Entonces*

$$(E[(W_n)^p])^{1/p} \leq \frac{p}{p-1} (E[|X_n|^p])^{1/p}.$$

Para la última desigualdad de esta sección introducimos la noción de cruces hacia arriba (*upcrossings*). Sea  $\{X_n, n \geq 0\}$  una submartingala y sea  $a < b$ . El número de cruces hacia arriba del intervalo  $[a, b]$  es el número de veces que el proceso pasa de estar por debajo de  $a$  a estar por encima de  $b$  en un tiempo posterior. Esta idea se puede expresar de manera simple con tiempos de paro. Definimos  $T_0 = 0$  e inductivamente para  $j \geq 0$

$$S_{j+1} = \text{mín}\{k > T_j : X_k \leq a\}, \quad T_{j+1} = \text{mín}\{k > S_{j+1} : X_k \geq b\} \quad (5.17)$$

con la convención usual de que el mínimo de un conjunto vacío es  $+\infty$ . Tomando como convención que el máximo de un conjunto vacío es 0, definimos

$$U_n = \text{máx}\{j : T_j \leq n\}, \quad (5.18)$$

$U_n$  es el número de cruces hacia arriba de  $[a, b]$  al tiempo  $n$

**Teorema 5.21 (Desigualdad de Doob para cruces hacia arriba)** *Sea  $\{X_n, n \geq 0\}$  una submartingala, sean  $a < b$  y sea  $U_n$  el número de cruces hacia arriba de  $[a, b]$  al tiempo  $n$  según la definición (5.18). Entonces*

$$\mathbb{E}[U_n] \leq \frac{1}{b-a} \mathbb{E}[(X_n - a)^+]$$

donde  $(X_n - a)^+ = \text{máx}\{X_n - a, 0\}$ .

**Demostración.** Sea  $Y_n = (X_n - a)^+$ . Como la función  $\varphi(x) = (x - a)^+$  es convexa y no-decreciente, tenemos que  $(Y_n)$  es una submartingala. Como  $S_{n+1} > n$  obtenemos

$$Y_n = Y_{S_1 \wedge n} + \sum_{i=1}^n (Y_{T_i \wedge n} - Y_{S_i \wedge n}) + \sum_{i=1}^n (Y_{S_{i+1} \wedge n} - Y_{T_i \wedge n}) \quad (5.19)$$

Cada cruce hacia arriba de  $(X_n)$  entre los tiempos 0 y  $n$  corresponde a un entero  $i$  tal que  $S_i < T_i \leq n$ , con  $Y_{S_i} = 0$  y  $Y_{T_i} = Y_{T_i \wedge n} \geq b - a$  mientras que  $Y_{T_i \wedge n} - Y_{S_i \wedge n} \geq 0$  por construcción para todo  $i$ . Por lo tanto

$$\sum_{i=1}^n (Y_{T_i \wedge n} - Y_{S_i \wedge n}) \geq (b - a)U_n.$$

Por (5.19) obtenemos

$$(b - a)U_n \leq Y_n - Y_{S_i \wedge n} - \sum_{i=1}^n (Y_{S_{i+1} \wedge n} - Y_{T_i \wedge n}),$$

y como  $Y_{S_1 \wedge n} \geq 0$  obtenemos

$$(b - a)U_n \leq Y_n - \sum_{i=1}^n (Y_{S_{i+1} \wedge n} - Y_{T_i \wedge n}),$$

Tomamos esperanzas en ambos lados: Como  $(Y_n)$  es una submartingala, los tiempos de paro  $T_i \wedge n$  y  $S_{i+1} \wedge n$  están acotados y  $T_i \wedge n \leq S_{i+1} \wedge n$  tenemos  $\mathbb{E}[Y_{S_{i+1} \wedge n} - Y_{T_i \wedge n}] \geq 0$  y por lo tanto

$$(b - a) \mathbb{E}[U_n] \leq \mathbb{E}[Y_n].$$

■

## 5.9. Teoremas de Convergencia.

**Teorema 5.22 (Teorema de Convergencia de Martingalas)** *Sea  $\{X_n, n \geq 1\}$  una submartingala tal que  $\sup_n E(X_n^+) < \infty$ . Entonces  $\lim_{n \rightarrow \infty} X_n = X$  existe c.s. y es finito c.s. Además,  $X \in L^1$ .*

**Observación 5.4** El teorema no dice que hay convergencia en  $L^1$ . Esto no es cierto en general.

**Demostración.** Sea  $U_n$  el número de cruces hacia arriba de  $[a, b]$  antes de  $n$ , entonces  $U_n$  es no-decreciente y por lo tanto  $U(a, b) = \lim_{n \rightarrow \infty} U_n$  existe. Por el teorema de convergencia monótona

$$\begin{aligned} E[U(a, b)] &= \lim_{n \rightarrow \infty} E[U_n] \\ &\leq \frac{1}{b-a} \sup_n E[(X_n - a)^+] \\ &\leq \frac{1}{b-a} (\sup_n E[X_n^+] + |a|) \leq \frac{c}{b-a} < \infty \end{aligned}$$

para alguna constante  $c$  que por hipótesis satisface  $c < \infty$ . La primera desigualdad viene del teorema 5.21 y la segunda de  $(x - a)^+ \leq x^+ + |a|$  para  $a, x \in \mathbb{R}$ . Como  $E[U(a, b)] < \infty$ , tenemos  $P(U(a, b) < \infty) = 1$ . En consecuencia  $X_n$  cruza  $[a, b]$  hacia arriba sólo un número finito de veces c.s. y si ponemos

$$\Lambda_{a,b} = \{\limsup_{n \rightarrow \infty} X_n \geq b; \liminf_{n \rightarrow \infty} X_n \leq a\},$$

entonces  $P(\Lambda_{a,b}) = 0$ . Sea

$$\Lambda = \bigcup_{\substack{a < b \\ a, b \in \mathbb{Q}}} \Lambda_{a,b},$$

entonces  $P(\Lambda) = 0$  ya que los pares de racionales son numerables. Pero

$$\Lambda = \{\limsup_n X_n > \liminf_n X_n\},$$

y concluimos que  $\lim_{n \rightarrow \infty} X_n$  existe c.s.

Veamos que el límite es finito. Como  $X_n$  es una submartingala,  $E(X_n) \geq E(X_0)$ , y en consecuencia,

$$E(|X_n|) = E(X_n^+) + E(X_n^-) = 2E(X_n^+) - E(X_n) \leq 2E(X_n^+) - E(X_0), \quad (5.20)$$

y por lo tanto

$$E(\lim_n |X_n|) \leq \liminf_{n \rightarrow \infty} E(|X_n|) \leq 2 \sup_n E(X_n^+) - E(X_0) < \infty,$$

donde hemos usado el lema de Fatou, (5.20) y la hipótesis de que  $\sup_n E(X_n^+) < \infty$ . Por lo tanto  $X_n$  converge c.s. a un límite finito  $X$ . Hemos mostrado además que  $E(|X|) = E(\lim_n |X_n|) < \infty$ , de modo que  $X \in L^1$ . ■

**Corolario 5.4** *Si  $X_n$  es una supermartingala no-negativa, o una martingala acotada superior o inferiormente, entonces  $\lim_{n \rightarrow \infty} X_n = X$  existe c.s. y  $X \in L^1$ .*

**Demostración.** Si  $X_n$  es una supermartingala no-negativa,  $(-X_n)$  es una submartingala acotada superiormente por 0 y podemos usar el teorema anterior.

Si  $X_n$  es una martingala acotada inferiormente, entonces  $X_n \geq -c$  c.s. para todo  $n$  para alguna constante  $c > 0$ . Sea  $Y_n = X_n + c$ , entonces  $Y_n$  es una martingala no-negativa y por lo tanto también una supermartingala no-negativa y podemos aplicar lo que hemos demostrado del corolario. Si  $X_n$  es una martingala acotada superiormente entonces  $-X_n$  es una martingala acotada inferiormente. ■

**Ejemplo 5.17**

Consideremos un paseo al azar simple:  $X_n = \sum_{k=1}^n Y_k$  donde las variables  $Y_k$ ,  $k \geq 1$  son independientes con distribución de Bernoulli de parámetro  $1/2$ . No es difícil demostrar que el paseo al azar  $\{X_n, n \geq 1\}$  no converge porque oscila con excursiones que se alejan cada vez más del origen, pero regresa al origen infinitas veces.

Por el TCL sabemos que  $X_n/\sqrt{n} \rightarrow \mathcal{N}(0, 1)$  en distribución y en  $L^1$  y por lo tanto  $E|X_n| \sim (2n/\pi)^{1/2}$  cuando  $n \rightarrow \infty$ .

Para obtener convergencia en  $L^1$  necesitamos la hipótesis de integrabilidad uniforme. Recordemos la definición de este concepto.

**Definición 5.16** Una colección de variables aleatorias  $\mathcal{H} \subset L^1$  es *uniformemente integrable* si

$$\lim_{a \rightarrow \infty} \sup_{X \in \mathcal{H}} E[|X| \mathbf{1}_{\{|X| \geq a\}}] = 0.$$

Recordamos también las siguientes condiciones suficientes para integrabilidad uniforme, que están contenidas en la sección 1.6.

**Teorema 5.23** Sea  $\mathcal{H}$  una clase de variables aleatorias

- a) Si  $\sup_{X \in \mathcal{H}} E(|X|^p) < \infty$  para algún  $p > 1$ , entonces  $\mathcal{H}$  es uniformemente integrable.
- b) Si existe una v.a.  $Y$  tal que  $|X| \leq Y$  c.s. para toda  $X \in \mathcal{H}$  y  $E(Y) < \infty$ , entonces  $\mathcal{H}$  es uniformemente integrable.

**Definición 5.17** Decimos que una martingala  $\{(X_n, \mathcal{F}_n), n \geq 1\}$  es *cerrada, regular o completa* si existe una variable aleatoria  $Y$  con  $E(|Y|) < \infty$  y  $X_n = E(Y|\mathcal{F}_n)$  para todo  $n$ .

**Teorema 5.24 (Teorema de Convergencia de Martingalas)** a) Sea  $\{X_n, n \geq 1\}$  una martingala uniformemente integrable. Entonces

$$\lim_{n \rightarrow \infty} X_n = X_\infty \quad \text{existe c.s.}$$

$X_\infty \in L^1$  y  $X_n$  converge a  $X_\infty$  en  $L^1$ . Además  $X_n = E(X_\infty|\mathcal{F}_n)$ .

b) Recíprocamente sea  $Y \in L^1$  y consideremos la martingala  $X_n = E(Y|\mathcal{F}_n)$ . Entonces  $\{X_n, n \geq 1\}$  es uniformemente integrable.

En otras palabras, la martingala es regular si y sólo si es uniformemente integrable.

**Demostración.**

a) Como  $\{X_n\}$  es uniformemente integrable, para  $\varepsilon > 0$  existe  $c$  tal que  $\sup_n E(|X_n| \mathbf{1}_{\{|X_n| \geq c\}}) \leq \varepsilon$ . Por lo tanto

$$E(|X_n|) = E(|X_n| \mathbf{1}_{\{|X_n| \geq c\}}) + E(|X_n| \mathbf{1}_{\{|X_n| < c\}}) \leq \varepsilon + c.$$

Así  $(X_n)_{n \geq 1}$  está acotada en  $L^1$  y en consecuencia  $\sup_n E(X_n^+) < \infty$ . Por el teorema 5.22 tenemos que

$$\lim_{n \rightarrow \infty} X_n = X_\infty$$

existe c.s. y  $X_\infty \in L^1$ .

Para ver que  $X_n$  converge a  $X_\infty$  en  $L^1$ , definimos

$$f_c(x) = \begin{cases} c & \text{si } x > c, \\ x & \text{si } |x| \leq c, \\ -c & \text{si } x < -c. \end{cases}$$

Entonces  $f_c$  es Lipschitz. Por integrabilidad uniforme existe  $c$  suficientemente grande tal que para  $\varepsilon > 0$  dado

$$\mathbb{E}(|f_c(X_n) - X_n|) < \frac{\varepsilon}{3} \quad \text{para todo } n, \quad (5.21)$$

$$\mathbb{E}(|f_c(X_\infty) - X_\infty|) < \frac{\varepsilon}{3}. \quad (5.22)$$

Como  $\lim X_n = X_\infty$  c.s. tenemos  $\lim_{n \rightarrow \infty} f_c(X_n) = f_c(X_\infty)$  y por el TCD tenemos para  $n \geq N$ ,  $N$  suficientemente grande

$$\mathbb{E}(|f_c(X_n) - f_c(X_\infty)|) < \frac{\varepsilon}{3} \quad (5.23)$$

Usando (5.21), (5.22) y (5.23) tenemos

$$\mathbb{E}(|X_n - X_\infty|) < \varepsilon, \quad \text{para } n \geq N.$$

Por lo tanto  $X_n \rightarrow X_\infty$  en  $L^1$ . Falta demostrar que  $\mathbb{E}(X_\infty | \mathcal{F}_n) = X_n$ . Sea  $\Lambda \in \mathcal{F}_m$  y  $n \geq m$ , entonces

$$\mathbb{E}(X_n \mathbf{1}_\Lambda) = \mathbb{E}(X_m \mathbf{1}_\Lambda)$$

por la propiedad de martingala. Sin embargo,

$$|\mathbb{E}(X_n \mathbf{1}_\Lambda) - \mathbb{E}(X_\infty \mathbf{1}_\Lambda)| \leq \mathbb{E}(|X_n - X_\infty| \mathbf{1}_\Lambda) \leq \mathbb{E}(|X_n - X_\infty|)$$

que tiende a 0 cuando  $n \rightarrow \infty$ . Por lo tanto  $\mathbb{E}(X_m \mathbf{1}_\Lambda) = \mathbb{E}(X_\infty \mathbf{1}_\Lambda)$  y  $\mathbb{E}(X_\infty | \mathcal{F}_n) = X_n$  c.s.

b) Ya sabemos que  $\{X_n, n \geq 1\}$  es una martingala. Si  $c > 0$  tenemos

$$X_n \mathbf{1}_{\{|X_n| \geq c\}} = E(Y | \mathcal{F}_n) \mathbf{1}_{\{|X_n| \geq c\}} = E(Y \mathbf{1}_{\{|X_n| \geq c\}} | \mathcal{F}_n),$$

porque  $\{|X_n| \geq c\} \in \mathcal{F}_n$ . para cualquier  $d > 0$  tenemos

$$\begin{aligned} \mathbb{E}(|X_n| \mathbf{1}_{\{|X_n| \geq c\}}) &\leq \mathbb{E}(|Y| \mathbf{1}_{\{|X_n| \geq c\}}) \\ &\leq \mathbb{E}(|Y| \mathbf{1}_{\{|Y| > d\}}) + dP(|X_n| \geq c) \\ &\leq \mathbb{E}(|Y| \mathbf{1}_{\{|Y| > d\}}) + \frac{d}{c} \mathbb{E}(|X_n|) \\ &\leq \mathbb{E}(|Y| \mathbf{1}_{\{|Y| > d\}}) + \frac{d}{c} \mathbb{E}(|Y|). \end{aligned} \quad (5.24)$$

Tomamos  $\varepsilon > 0$  y escogemos  $d$  de modo que el primer término de (5.24) sea menor que  $\varepsilon/2$ , y luego escogemos  $c$  de modo que el segundo término también sea menor que  $\varepsilon/2$ . Hemos demostrado que  $\mathbb{E}(|X_n| \mathbf{1}_{\{|X_n| > c\}}) \leq \varepsilon$ . ■

**Corolario 5.5** Sea  $\{\mathcal{F}_n, n \geq 0\}$  una filtración y  $\mathcal{F}_\infty = \sigma(\cup_{n \geq 0} \mathcal{F}_n)$  la  $\sigma$ -álgebra generada por la filtración. Si  $Y \in L^1(\mathcal{F}_\infty)$  entonces

$$\lim_{n \rightarrow \infty} \mathbb{E}[Y | \mathcal{F}_n] = Y$$

donde el límite es c.s. y en  $L^1$ .

**Demostración.**

Sea  $X_n = \mathbb{E}(Y | \mathcal{F}_n)$ , entonces  $X_n$  es una martingala uniformemente integrable. Observemos que si  $\Lambda \in \mathcal{F}_m$

$$\int_\Lambda Y dP = \int_\Lambda X_n dP \rightarrow \int_\Lambda X_\infty dP$$

cuando  $n \rightarrow \infty$ . Esto permite demostrar que

$$\int_\Lambda Y dP = \int_\Lambda X_\infty dP \quad \forall \Lambda \in \mathcal{F}_\infty$$

y en consecuencia

$$X_\infty = E(Y|\mathcal{F}_\infty) = Y.$$

porque  $Y \in \mathcal{F}_\infty$  ■

### Ejemplo 5.18

Recordemos el ejemplo 4.10 en el cual se duplica la apuesta cuando se pierde:  $X_0 = 0$  y

$$X_{n+1} = \begin{cases} 2X_n, & \text{con probabilidad } 1/2, \\ 0 & \text{con probabilidad } 1/2 \end{cases}$$

Vimos que  $\{(X_n, \mathcal{F}_n), n \geq 0\}$  es una martingala multiplicativa con media 1.

Como  $P(X_n = 2^n) = 1 - P(X_n = 0) = 2^{-n}$ , una aplicación del lema de Borel-Cantelli muestra que  $X_n \rightarrow 0$  c.s. cuando  $n \rightarrow \infty$ . Pero  $E(X_n = 1)$  para todo  $n$ , el valor esperado no converge a 0, de modo que la martingala no es uniformemente integrable y no es regular.

Una aplicación del teorema de convergencia de martingalas es la siguiente.

**Teorema 5.25 (Kolmogorov)** Sea  $(Y_n, n \geq 1)$  v.a.i. centradas con  $E(Y_n^2) < \infty$  para todo  $n$ . Supongamos que  $\sum_{n=1}^{\infty} E(Y_n^2) < \infty$ . Sea  $S_n = \sum_{j=1}^n Y_j$ , entonces

$$\lim_{n \rightarrow \infty} S_n = \sum_{j=1}^{\infty} Y_j$$

existe c.s. y es finito c.s.

**Demostración.** Sea  $\mathcal{F}_n = \sigma(Y_1, \dots, Y_n)$  y observemos que

$$E(S_{n+1} - S_n | \mathcal{F}_n) = E(Y_{n+1} | \mathcal{F}_n) = E(Y_{n+1}) = 0$$

de modo que  $(S_n, n \geq 1)$  es una  $\mathcal{F}_n$ -martingala. Observamos además que

$$\sup_n E(S_n^+) \leq \sup_n (E(S_n^2) + 1) \leq \sum_{k=1}^{\infty} E(Y_k^2) + 1 < \infty.$$

El resultado sigue del teorema de convergencia de martingalas. ■

**Definición 5.18** Consideremos ahora una sucesión creciente de  $\sigma$ -álgebras con índices negativos  $\{\mathcal{F}_{-n}, n \geq 0\}$ , es decir que  $\mathcal{F}_{-(n+1)} \subset \mathcal{F}_{-n}$ . Una *martingala invertida* es una sucesión  $\{X_{-n}, n \geq 0\}$  de v.a. integrables con  $X_{-n} \in \mathcal{F}_{-n}$  y satisface

$$E[X_{-n} | \mathcal{F}_{-m}] = X_{-m} \tag{5.25}$$

con  $0 \leq n < m$ .

Una diferencia fundamental entre una martingala y una martingala invertida es que esta última tiene último elemento pero no tiene primer elemento, mientras que para una martingala es lo contrario.

Por la definición tenemos que

$$E(X_0 | \mathcal{F}_{-n}) = X_{-n}, \quad \text{para todo } n \geq 0$$

lo que implica que una martingala invertida es regular y por lo tanto uniformemente integrable.

**Teorema 5.26 (Teorema de Convergencia para Martingalas Invertidas)** Sea  $\{(X_{-n}, \mathcal{F}_{-n}), n \geq 0\}$  una martingala invertida, y sea  $\mathcal{F}_{-\infty} = \cap_{n=0}^{\infty} \mathcal{F}_{-n}$ . Entonces la sucesión  $(X_{-n})$  converge c.s. y en  $L^1$  a un límite  $X$  cuando  $n \rightarrow +\infty$ . En particular  $X$  es c.s. finita e integrable.

**Demostración.** Sea  $U_{-n}$  el número de cruces hacia arriba del intervalo  $[a, b]$  por  $(X_{-n})_{n \geq 0}$  entre el instante  $-n$  y 0. Entonces  $U_{-n}$  crece con  $n$  y sea  $U(a, b) = \lim_{n \rightarrow \infty} U_{-n}$ . Por el TCM

$$\mathbb{E}[U(a, b)] = \lim_{n \rightarrow \infty} \mathbb{E}[U_{-n}] \leq \frac{1}{b-a} \mathbb{E}[(X_0 - a)^+] < \infty,$$

por lo tanto  $P(U(a, b) < \infty) = 1$ . El mismo argumento usado en la demostración del teorema 5.22 implica que  $X = \lim_{n \rightarrow \infty} X_{-n}$  existe c.s.

Sea  $\varphi(x) = x^+ = (x \wedge 0)$ , que es convexa y creciente. Además  $\varphi(X_{-n})$  es integrable para todo  $n$ . La desigualdad de Jensen y (5.25) implican que  $X_{-n}^+ \leq \mathbb{E}(X_0^+ | \mathcal{F}_{-n})$ , de modo que  $\mathbb{E}(X_{-n}^+) \leq \mathbb{E}(X_0^+)$ . Por el lema de Fatou y como  $X_{-n}^+ \geq 0$  y  $X_{-n}^+ \rightarrow X^+$  c.s. obtenemos

$$\mathbb{E}(X^+) \leq \liminf_n \mathbb{E}(X_{-n}^+) \leq \mathbb{E}(X_0^+) < \infty.$$

Por lo tanto  $X^+ \in L^1$  y el mismo argumento aplicado a la martingala  $(-X_{-n})$  muestra que  $X^- \in L^1$ . En consecuencia  $X \in L^1$ .

Falta demostrar que la convergencia también es en  $L^1$ . Observamos que en la demostración del teorema 5.24 vimos que si  $X_{-n} \rightarrow X$  c.s., si  $X \in L^1$  y si la sucesión  $(X_{-n})$  es uniformemente integrable entonces  $X_{-n} \rightarrow X$  en  $L^1$ . Todas estas condiciones se satisfacen en este caso. ■

Como aplicación demostramos la LFGN de Kolmogorov.

**Teorema 5.27 (LFGN)** Sea  $(X_n)_{n \geq 1}$  una sucesión i.i.d. con  $\mathbb{E}(|X_1|) < \infty$  y sea  $S_n = X_1 + \dots + X_n$ . Entonces

$$\lim_{n \rightarrow \infty} \frac{1}{n} S_n = \mathbb{E}(X_1) \quad \text{c.s.}$$

**Demostración.** Sea  $\mathcal{F}_{-n} = \sigma(S_n, S_{n+1}, S_{n+2}, \dots)$ . Entonces  $\mathcal{F}_{-n} \subset \mathcal{F}_{-m}$  si  $n \geq m$ , y el proceso

$$M_{-n} = \mathbb{E}(X_1 | \mathcal{F}_{-n})$$

es una martingala invertida. Observemos que  $\mathbb{E}(M_{-n}) = \mathbb{E}(X_1)$ , para todo  $n$ , y además, como la sucesión es i.i.d., para  $1 \leq j \leq n$

$$\mathbb{E}(X_1 | \mathcal{F}_{-n}) = \mathbb{E}(X_j | \mathcal{F}_{-n}) \quad \text{c.s.} \quad (5.26)$$

Por lo tanto,

$$M_{-n} = \mathbb{E}(X_1 | \mathcal{F}_{-n}) = \mathbb{E}(X_2 | \mathcal{F}_{-n}) = \dots = \mathbb{E}(X_n | \mathcal{F}_{-n}).$$

En consecuencia

$$M_{-n} = \frac{1}{n} \sum_{j=1}^n \mathbb{E}(X_j | \mathcal{F}_{-n}) = \frac{1}{n} \mathbb{E}(S_n | \mathcal{F}_{-n}) = \frac{1}{n} S_n \quad \text{c.s.}$$

Por el teorema 5.26

$$\lim_{n \rightarrow \infty} \frac{1}{n} S_n = X \quad \text{c.s.}$$

con  $\mathbb{E}(X) = \mathbb{E}(X_1)$ . Además  $X$  es medible respecto a la  $\sigma$ -álgebra cola, y por la ley 0-1 de Kolmogorov, tenemos que  $X$  es constante c.s. En consecuencia debe ser igual a su valor esperado. ■