

# Variables Aleatorias Discretas: Esperanza

Pablo L. De Nápoli

Departamento de Matemática  
Facultad de Ciencias Exactas y Naturales  
Universidad de Buenos Aires

Probabilidades y Estadística para Matemática  
Segundo cuatrimestre de 2021

# Parte I

## Variables Aleatorias Discretas

# Recordamos de la clase pasada

- Una **variable aleatoria** es un número asociado al resultado de un experimento aleatorio. Por ejemplo, cuando efectuamos una medición. Lo modelamos por una función  $X : \Omega \rightarrow \overline{\mathbb{R}}$ .
- Por razones técnicas, hay que pedir que  $X^{-1}(I)$  sea un evento para cada intervalo  $I \subset \overline{\mathbb{R}}$ , o sea que podamos calcular  $P\{X \in I\} = P(X^{-1}(I))$ .
- Hay distintos tipos de variables aleatorias. En esta clase focalizaremos en las **variables aleatorias discretas** para las cuales  $Im(X) = \{x_1, x_2, x_3, \dots\}$  [el conjunto de valores que toma  $X$ ] es finito o infinito numerable. En este caso, la distribución de  $X$  se especifica dando las probabilidades

$$p_i = P\{X = x_i\}$$

Notemos las  $p_i$  forman un **vector de probabilidades** (posiblemente infinito)

$$0 \leq p_i \leq 1, \quad \sum_i p_i = 1$$

# Un ejemplo

Tiramos dos dados. Nuestro espacio muestral es:

$$\Omega = \{\omega = (\omega_1, \omega_2) : \omega_i \in D\}$$

donde  $D = \{1, 2, 3, 4, 5, 6\}$ . Consideramos la suma  $S$  de los puntos obtenidos

$$S : \Omega \rightarrow \mathbb{N}, \quad S(\omega) = \omega_1 + \omega_2$$

Es una **variable aleatoria discreta**. ¿Cuál es la distribución de probabilidades de  $S$ ?

$x_i$	$p_i$
2	$1/36 = 0,028$
3	$2/36 = 0,056$
4	$3/36 = 0,083$
5	$4/36 = 0,111$
6	$5/36 = 0,139$
7	$6/36 = 0,167$
8	$5/36 = 0,139$
9	$4/36 = 0,111$
10	$3/36 = 0,083$
11	$2/36 = 0,056$
12	$1/36 = 0,028$

## Parte II

# La esperanza matemática

## Definición

Sea  $X : \Omega \rightarrow \mathbb{R}$  una variable aleatoria discreta. Diremos que  $X$  es integrable (o que tiene esperanza finita) si la serie

$$\sum_i p_i x_i$$

es absolutamente convergente, es decir si:

$$\sum_i p_i |x_i| < +\infty$$

En este caso definimos, la esperanza de  $X$  (también llamada *valor medio*) o *valor esperado*) como el valor de dicha suma.

$$E[X] = \sum_i p_i x_i$$

Nota: si  $X : \Omega \rightarrow \overline{\mathbb{R}} = \mathbb{R} \cup \{\pm\infty\}$ , entonces pedimos que  $X$  sea finita con probabilidad 1, o equivalentemente

# Esperanza de variable aleatorias con imagen finita

- Una variable aleatoria cuya imagen es finita siempre es integrable, ya que la suma

$$E[X] = \sum_i p_i x_i$$

es finita en este caso.

**Ejemplo** Supongamos que arrojamos un dado ¿cuál es la esperanza del valor obtenido  $X$  ?

$$E[X] = \frac{1 + 2 + 3 + 4 + 5 + 6}{6} = \frac{21}{6} = 3,5$$

# Ley de los grandes números (idea intuitiva)

Supongamos que tenemos una variable aleatoria discreta  $X$  y **repetimos el experimento** aleatorio asociado a  $X$  una cantidad de veces  $n$  (en condiciones independientes). Llamemos  $X_1, X_2, \dots, X_n$  a los valores obtenidos para nuestra variable y consideramos el promedio de dichos valores

$$\bar{X}_n = \frac{X_1 + X_2 + \dots + X_n}{n}$$

Llamemos  $n_i$  a la cantidad de veces que obtenemos uno de los valores  $x_i$  posibles para  $x_i$ , y  $f_i = n_i/n$  a la correspondiente **frecuencia**.

Entonces

$$S_n = X_1 + X_2 + \dots + X_n = \sum_i n_i \cdot x_i$$

y en consecuencia

$$\bar{X}_n = \sum_i f_i \cdot x_i$$

Ahora si  $n$  es grande, esperamos que  $f_i \approx p_i$  (**ley de los grandes números**) y por lo tanto que  $\bar{X}_n \approx E[X]$ . Matemáticamente nos gustaría decir que  $\bar{X}_n \rightarrow E[X]$  cuando  $n \rightarrow \infty$  **en algún sentido**. Formalizamos esto más adelante.



# Un ejemplo: La ruleta

Supongamos que jugamos un peso a la ruleta y apostamos a un color (por ej. negro). Sea  $X$  nuestra ganancia (o pérdida) ¿cuánto debemos esperar ganar (o perder) ?

Aquí

$$X = \begin{cases} 1 & \text{si sale negro} & (\text{con probabilidad } \frac{18}{37}) \\ -1 & \text{si sale rojo o cero} & (\text{con probabilidad } \frac{19}{37}) \end{cases}$$

En consecuencia:

$$E[X] = \frac{18}{37} - \frac{19}{37} = \frac{-1}{37} = -0,027 \dots$$

Así pues, al jugar a la ruleta, debemos esperar perder un 27 por mil.

# Variable indicadora de un evento

Sea  $A$  un evento, consideramos la función  $I_A : \Omega \rightarrow \mathbb{R}$  definida por

$$I_A(\omega) = \begin{cases} 1 & \text{si } \omega \in A \\ 0 & \text{si } \omega \notin A \end{cases}$$

Intuitivamente  $I_A$  vale 1 cuando el evento  $A$  ocurre, y 0 sino. Se denomina el indicador del evento  $A$ . (En la teoría de la medida, esta función se llama la función característica del conjunto  $A$  y se suele denotar por  $\chi_A$ , pero en la teoría de probabilidades la expresión “función característica” tiene un significado diferente).

$I_A$  es una variable aleatoria discreta pues su imagen consta de dos valores (0 y 1) y sus pre-imágenes son  $X^{-1}(0) = \Omega - A$  y  $X^{-1}(1) = A$ , que son eventos.

La esperanza de  $I_A$  es:

$$E[I_A] = 0 \cdot P(\Omega - A) + 1 \cdot P(A) = P(A)$$

Es decir, la esperanza del indicador de un evento, coincide con su probabilidad.

# Esperanzas en la computadora

Consideremos una variable aleatoria discreta con 3 valores 1, 2, 3 tal que

$$P\{X = 1\} = \frac{1}{2}, P\{X = 2\} = P\{X = 3\} = \frac{1}{4}$$

$$E[X] = 1 \cdot \frac{1}{2} + 2 \cdot \frac{1}{4} + 3 \cdot \frac{1}{4} = \frac{7}{4} = 1,75$$

Calculando la esperanza de una distribución de probabilidad discreta

```
import scipy.stats
xk = (1, 2, 3)
pk = (0.5, 0.25, 0.25)
distribucion = scipy.stats.rv_discrete(values=(xk, pk))
print(distribucion.mean())
```

# Un ejemplo de una variable aleatoria que toma infinitos valores y que puede valor infinito

En la clase pasada, consideramos en el **esquema de infinitos ensayos de Bernoulli** cuántos ensayos debemos realizar hasta obtener el primer éxito. Vimos que esto define una variable aleatoria  $T : \Omega^\infty \rightarrow \mathbb{N} \cup \{+\infty\}$  con la **distribución geométrica** de parámetro  $p$ .

$$P\{T = k\} = q^{k-1} \cdot p$$

$$P\{T = +\infty\} = 0$$

donde recordamos que  $q = 1 - p$ .

Por ejemplo: tiramos infinita veces una moneda (con  $p = q = 1/2$ ) ¿cuánto debemos esperar hasta que salga la primer cara?

¿Cuál es la esperanza de  $T$ ?

$$E[T] = \sum_{k=1}^{\infty} k q^{k-1} \cdot p$$

# Calculando la esperanza de la distribución geométrica

Para sumar esta serie, debemos recordar que la distribución geométrica se llama así porque está emparentada con la **serie geométrica**

$$\frac{1}{1-x} = \sum_{k=0}^{\infty} x^k \quad |x| < 1$$

Si derivamos esta serie, tenemos:

$$\frac{1}{(1-x)^2} = \sum_{k=1}^{\infty} kx^{k-1} \quad |x| < 1$$

Entonces:

$$E[T] = p \cdot \sum_{k=1}^{\infty} k q^{k-1} = \frac{p}{(1-q)^2} = \frac{p}{p^2} = \frac{1}{p}$$

Para su tabla de esperanzas

$$T \sim \text{Ge}(p) \Rightarrow E[T] = \frac{1}{p}$$

# Esperanzas infinitas

A veces resulta conveniente admitir esperanzas infinitas. Si  $X \geq 0$  diremos que  $E[X] = +\infty$  si

$$\sum_i x_i P\{X = x_i\}$$

diverge.

Si  $X$  es una variable aleatoria discreta cualquiera, escribimos

$$X = X^+ - X^-$$

donde

$$X^+ = \begin{cases} X & \text{si } X \geq 0 \\ 0 & \text{si } X < 0 \end{cases}$$

y

$$X^- = \begin{cases} -X & \text{si } X < 0 \\ 0 & \text{si } X \geq 0 \end{cases}$$

Notamos que  $X^+$  y  $X^-$  son variables aleatorias no negativas.

Decimos que  $E[X] = +\infty$  si  $E[X^+] = +\infty$  y  $E[X^-] < \infty$ . Similarmente diremos que  $E[X] = -\infty$  si  $E[X^-] = +\infty$  y  $E[X^+] < \infty$ . Si  $E[X^+]$  y  $E[X^-]$  son ambas infinitas,  $E[X]$  no está definida.

## Proposición (linealidad de la esperanza)

- 1 Si  $X, Y : \Omega \rightarrow \mathbb{R}$  son variables aleatorias discretas con esperanza finita, entonces

$$E[X + Y] = E[X] + E[Y]$$

- 2 Si  $X : \Omega \rightarrow \mathbb{R}$  es una variable aleatoria discreta con esperanza finita, entonces:

$$E[\lambda X] = \lambda E[X]$$

# Demostración

Sean  $(x_i)$  los valores que toma  $X$ , e  $(y_j)$  los valores que toma  $Y$ : entonces

$$E[X] = \sum_i x_i P\{X = x_i\} = \sum_{i,j} x_i P\{X = x_i, Y = y_j\}$$

ya que

$$\{X = x_i\} = \bigcup_j \{X = x_i, Y = y_j\} \text{ (unión disjunta)}$$

y el reordenamiento de la serie está justificado por la convergencia absoluta, de la serie:

$$\sum_{i,j} x_i P\{X = x_i, Y = y_j\}$$

Similarmemente,

$$E[Y] = \sum_j y_j P\{Y = y_j\} = \sum_{i,j} y_j P\{X = x_i, Y = y_j\}$$

$$E[X] + E[Y] = \sum_{i,j} (x_i + y_j) P\{X = x_i, Y = y_j\}$$

$p_{ij} = P\{X = x_i, Y = y_j\}$  se llaman la **distribución conjunta** de  $X$  e  $Y$ .



## Demostración (2)

Sea  $Z = X + Y$  y sean  $z_1, z_2, \dots, z_k, \dots$  los valores de  $Z$ . Entonces los  $z_k$  son exactamente los valores  $x_i + y_j$  (pero estos últimos pueden repetirse). Entonces,

$$E[Z] = \sum_k z_k P\{Z = z_k\} = \sum_k \sum_{i,j: x_i + y_j = z_k} z_k P\{X = x_i, Y = y_j\}$$

pues

$$\{Z = z_k\} = \bigcup_{i,j: x_i + y_j = z_k} \{X = x_i, Y = y_j\} \text{ (unión disjunta)}$$

Deducimos que

$$E[Z] = \sum_k (x_i + y_j) P\{X = x_i, Y = y_j\} = E[X] + E[Y]$$

Esto completa la prueba de la primera afirmación. En cuanto a la segunda afirmación,  $\lambda X$  es una variable aleatoria discreta que toma los valores  $\lambda x_i$ , por lo tanto:

$$E[\lambda X] = \sum_i \lambda x_i P\{\lambda X = \lambda x_i\} = \lambda \sum_i x_i P\{X = x_i\} = \lambda E[X]$$

# Un ejemplo que ya vimos: el esquema de ensayos de Bernouli

Consideramos un experimento aleatorio con dos resultados que convencionalmente se llaman

- éxito (1) con probabilidad  $p$ .
- fracaso(0) con probabilidad  $q = 1 - p$ .

Introducimos las **variables aleatorias de Bernoulli**  $X_i : \Omega^\infty \rightarrow \mathbb{R}$  dadas por

$$X_i = \begin{cases} 1 & \text{si la } i\text{-ésima realización del experimento es un éxito} \\ 0 & \text{si la } i\text{-ésima realización del experimento es un fracaso} \end{cases}$$

Las  $X_i$  son variables aleatorias discretas. También lo es el número de éxitos en  $n$  ensayos.

$$S_n = X_1 + X_2 + \dots + X_n$$

Como ya vimos  $S_n$  tiene **distribución binomial**;  $S_n \sim Bi(n, p)$

$$P\{S_n = k\} = b(k, n, p) = \binom{n}{k} p^k q^{n-k}, \quad 0 \leq k \leq n$$

# ¿Cómo calcular la esperanza de la distribución binomial?: Método 1

Una forma de calcular la esperanza de  $S_n$  sería usar directamente la definición

$$E[S_n] = \sum_{k=0}^n k P\{S_n = k\} = \sum_{k=0}^n k \binom{n}{k} p^k q^{n-k} = \sum_{k=1}^n k \binom{n}{k} p^k q^{n-k}$$

Para hacer esto, usamos un truco parecido al que usamos para la distribución geométrica:

$$(px + q)^n = \sum_{k=0}^n \binom{n}{k} x^k p^k q^{n-k}$$

derivando

$$np(px + q)^{n-1} = \sum_{k=1}^n \binom{n}{k} k x^{k-1} p^k q^{n-k}$$

Especializando en  $x = 1$ , como  $p + q = 1$ , vemos que

$$E[S_n] = np$$

# ¿Cómo calcular la esperanza de la distribución binomial?: Método 2

Como

$$S_n = X_1 + X_2 + \dots + X_n$$

donde las  $X_i$  son las variables aleatorias de Bernoulli, entonces por la **linealidad de la esperanza**

$$E[S_n] = E[X_1] + E[X_2] + \dots + E[X_n] = np$$

Para su tabla de esperanzas

$$S_n \sim \text{Bi}(n, p) \Rightarrow E[S_n] = np$$

Fíjense que si  $f_n = \frac{S_n}{n}$  representa la **frecuencia de éxitos** en  $n$  ensayos, entonces

$$E[f_n] = p$$

## Proposición (Monotonía de la esperanza)

- 1 Si  $X$  es una variable aleatoria con esperanza finita y  $X \geq 0$  con probabilidad 1, entonces  $E[X] \geq 0$ .
- 2 Sean  $X$  e  $Y$  variables aleatorias con esperanza finita. Entonces, si  $X \leq Y$  con probabilidad 1, tenemos que  $E[X] \leq E[Y]$

- 3 Si  $X$  es una variable aleatoria acotada, entonces:

$$\inf_{\Omega} X \leq E[X] \leq \sup_{\Omega} X$$

- 4 Si  $X$  es una variable aleatoria discreta con esperanza finita, entonces:

$$|E[X]| \leq E[|X|]$$

# Esperanza de una función de una variable aleatoria

## Proposición

Sean  $X$  una variable aleatoria discreta y  $\varphi : \mathbb{R} \rightarrow \mathbb{R}$ . Entonces

$$E[\varphi(X)] = \sum_i \varphi(x_i)P\{X = x_i\}$$

siempre que esta serie sea absolutamente convergente.

## Demostración.

Sea  $Y = \varphi(X)$ , y sean  $(y_j)$  los valores de  $Y$ , entonces:

$$\begin{aligned} E[Y] &= \sum_j y_j P\{Y = y_j\} = \sum_j y_j \sum_{i:\varphi(x_i)=y_j} P\{X = x_i, Y = y_j\} \\ &= \sum_i \varphi(x_i)P\{X = x_i\} \end{aligned}$$

(El reordenamiento se justifica usando la convergencia absoluta de la serie.) □

# Un ejemplo

Supongamos que  $S_n \sim \text{Bi}(n, p)$  con  $n \geq 2$ , y que queremos calcular  $E[S_n^2]$ . Según la fórmula anterior con  $\varphi(x) = x^2$

$$E[S_n^2] = \sum_{k=0}^n k^2 P\{S_n = k\} = \sum_{k=0}^n k^2 \binom{n}{k} p^k q^{n-k}.$$

Recordamos que

$$(px + q)^n = \sum_{k=0}^n \binom{n}{k} x^k p^k q^{n-k}$$

Derivando dos veces

$$n(n-1)p(px + q)^{n-2} = \sum_{k=2}^n \binom{n}{k} k(k-1)x^{k-2} p^k q^{n-k}$$

y especializando en  $x = 1$ , tenemos eligiendo  $\varphi(x) = x(x-1)$

$$n(n-1)p = \sum_{k=2}^n \binom{n}{k} k(k-1)p^k q^{n-k} = E[S_n(S_n - 1)]$$

## Un ejemplo (2)

pero por la linealidad de la esperanza

$$E[S_n(S_n - 1)] = E[S_n^2 - S_n] = E[S_n^2] - E(S_n)$$

y ya vimos que  $E[S_n] = np$  entonces ,

$$E[S_n^2] = E[S_n(S_n - 1)] + E[S_n] = n(n - 1)p + np = n^2p$$



# Vectores aleatorios

Esta propiedad se puede generalizar a funciones de **vectores aleatorios**. Este concepto es una generalización natural del de variable aleatoria discreta:

## Definición

*Un vector aleatorio discreto  $n$ -dimensional es una función  $X : \Omega \rightarrow \mathbb{R}^n$  tal que  $\text{Im}(X)$  sea finita o infinita numerable, y  $P\{X = x\}$  sea un evento para todo  $x \in \mathbb{R}^n$ . Dar un vector aleatorio discreto  $X = (X_1, X_2, \dots, X_n)$  es equivalente a dar  $n$  variables aleatorias discretas  $x_1, x_2, \dots, x_n$*

Con esta terminología tenemos [con la misma demostración de antes]:

## Proposición

*Sean  $X$  un vector aleatorio  $n$ -dimensional y  $\varphi : \mathbb{R}^n \rightarrow \mathbb{R}$ , entonces*

$$E[\varphi(X)] = \sum_i \varphi(x_i)P\{X = x_i\}$$

*donde  $x_i$  recorre la imagen de  $X$ , siempre que esta serie sea absolutamente convergente.*

## Definición

Sean  $X$  e  $Y$  dos variables aleatorias discretas definidas en un mismo espacio muestral. Diremos que son **independientes**, si para cada  $x_i, y_j$  los eventos  $\{X = x_i\}$  e  $\{Y = y_j\}$  son independientes, es decir de acuerdo a la definición de eventos independientes si,

$$P\{X = x_i, Y = y_j\} = P\{X = x_i\} \cdot P\{Y = y_j\}$$

**Observación:** Remarcamos que esta definición solamente se aplica a variables discretas, cuando generalicemos esta noción a variables aleatorias no discretas, nos veremos en la necesidad de adoptar una definición diferente.

## Proposición

Si  $X$  e  $Y$  son variables aleatorias discretas independientes, y  $f, g : \mathbb{R} \rightarrow \mathbb{R}$  son funciones, entonces  $Z = f(X)$  y  $W = g(Y)$  también son variables aleatorias discretas independientes.

## Demostración.

Calculemos la distribución conjunta de  $Z$  y  $W$ :

$$\begin{aligned} P\{Z = z, W = w\} &= \sum_{x,y:f(x)=z,g(y)=w} P\{X = x, Y = y\} \\ &= \sum_{x,y:f(x)=z,g(y)=w} P\{X = x\}P\{Y = y\} \\ &= \left( \sum_{x:f(x)=z} P\{X = x\} \right) \left( \sum_{y:g(y)=w} P\{Y = y\} \right) = P\{Z = z\}P\{W = w\} \end{aligned}$$



## Proposición

Si  $X$  e  $Y$  son variables aleatorias discretas independientes con esperanza finita, entonces:

$$E(XY) = E(X)E(Y)$$

## Demostración.

$$E[XY] = \sum_{i,j} x_i y_j P\{X = x_i, Y = y_j\} = \sum_{i,j} x_i y_j P\{X = x_i\} P\{Y = y_j\}$$

$$\left( \sum_i x_i P\{X = x_i\} \right) \left( \sum_j y_j P\{Y = y_j\} \right) = E[X]E[Y]$$

**Observación:** En el caso en que  $X$  e  $Y$  toman infinitos valores, la aplicación de la propiedad distributiva, está justificada por el hecho de que las series que intervienen son absolutamente convergentes, por hipótesis. □

# Un ejemplo

En el **esquema de ensayos de Bernoulli** las variables  $X_i$  las **variables aleatorias de Bernoulli**  $X_i : \Omega^\infty \rightarrow \mathbb{R}$  dadas por

$$X_i = \begin{cases} 1 & \text{si la } i\text{-ésima realización del experimento es un éxito} \\ 0 & \text{si la } i\text{-ésima realización del experimento es un fracaso} \end{cases}$$

son variables independientes. Entonces

$$E[X_i X_j] = E[X_i]E[X_j] = p \cdot p = p^2$$

## Definición

Sea  $I = [a, b] \subset \overline{\mathbb{R}}$  un intervalo y  $f : I \rightarrow \mathbb{R}$  una función. Diremos que  $f$  es convexa, si dados  $x_1, x_2 \in I$  y  $\alpha \in [0, 1]$ , se verifica que:

$$f(\alpha x_1 + (1 - \alpha)x_2) \leq \alpha f(x_1) + (1 - \alpha)f(x_2)$$

**Observación:** Si  $f$  es de clase  $C^2$ , entonces  $f$  es convexa, si y sólo si  $f''(x) \geq 0$ .

**Observación:** Una función convexa en  $\mathbb{R}$  es necesariamente continua. Además es posible probar que su derivada  $f'(x)$  existe salvo quizás para un conjunto a lo sumo numerable de valores de  $x$ , y que  $f'$  es creciente.

Ejemplos:  $f(x) = |x|^p$  si  $p \geq 1$ ,  $f(x) = e^x$ ,  $f(x) = |x|$



## Definición

Una **combinación convexa** de los  $x_i$  es una combinación lineal

$$\sum_{i=1}^n \alpha_i x_i$$

en la que  $0 \leq \alpha_i$  y  $\sum_{i=1}^n \alpha_i = 1$ .

## Ejercicio (de inducción)

Si  $f : \mathbb{R} \rightarrow \mathbb{R}$  es una función convexa y  $\sum_{i=1}^n \alpha_i x_i$  es una combinación convexa, entonces:

$$f\left(\sum_{i=1}^n \alpha_i x_i\right) \leq \sum_{i=1}^n \alpha_i f(x_i)$$



## Proposición (Desigualdad de Jensen)

Si  $g : \mathbb{R} \rightarrow \mathbb{R}$  es una función convexa, entonces:

$$g(E[X]) \leq E[g(X)]$$

en los siguientes casos: si  $X$  es no negativa y  $g(x) \geq 0$  para  $x \geq 0$ , o si  $X$  y  $g$  son arbitrarias y  $E(|g(X)|) < \infty$ .

# Demostración

Hagamos la demostración primero, en el caso que  $X$  toma sólo finitos valores. Sea  $p_i = P\{X = x_i\}$ . Entonces

$$E[X] = \sum_{i=1}^n p_i x_i$$

es una combinación convexa de los valores de  $X$ . Como  $X$  es una función convexa,

$$g(E[X]) = g\left(\sum_{i=1}^n p_i x_i\right) \leq \sum_{i=1}^n p_i g(x_i) = E[g(X)]$$

Si  $X$  toma un número numerable de valores,  $x_i$  con probabilidades  $p_i$ , entonces hacemos lo siguiente: para cada  $n \in \mathbb{N}$  definamos,

$$s_n = \sum_{i=1}^n p_i$$

y notamos que

$$\sum_{i=1}^n \frac{p_i}{s_n} x_i$$

es una combinación convexa.

## Demostración (2)

Entonces, como  $g$  es convexa:

$$g\left(\sum_{i=1}^n \frac{p_i}{s_n} x_i\right) \leq \sum_{i=1}^n \frac{p_i}{s_n} g(x_i)$$

Cuando  $n \rightarrow +\infty$ , tenemos que  $s_n \rightarrow 1$ . Entonces, utilizando la continuidad de  $g$ , obtenemos que:

$$g(E[X]) = g\left(\sum_{i=1}^{\infty} p_i x_i\right) \leq \sum_{i=1}^{\infty} p_i g(x_i) = E[g(X)]$$

## Parte III

# Momentos y Varianza

## Definición

Sea  $X$  una variable aleatoria (discreta). Definimos el  $k$ -ésimo momento de  $X$  entorno de  $b$  como  $E[(X - b)^k]$ . El  $k$ -ésimo momento absoluto entorno de  $b$  se define como  $E[|X - b|^k]$ .

Ejemplo: Antes calculamos que si  $n$  es el número de éxitos en  $n$  ensayo de Bernulli  $E[S_n^2] = E[|S_n|^2] = n^2 p$ . Esto da su segundo momento en torno al origen.

# Algunas observaciones:

- ① Si  $E[|X|^t] < \infty$  y  $0 \leq s \leq t$ , entonces  $E[|X|^s] < +\infty$ . En efecto según la desigualdad de Jensen,

$$(E[|X|^s])^p \leq E[|X|^t]$$

donde  $p = \frac{t}{s} \geq 1$ . Es más, vemos que:

- ②  $E[|X|^p]^{1/p}$  es una función creciente de  $p$ .
- ③ Si  $E[|X|^p] < +\infty$  y  $E[|Y|^p] < +\infty$  entonces  $E[|X + Y|^p]^{1/p} < +\infty$

## Demostración.

$$\begin{aligned} |X + Y|^p &\leq (|X| + |Y|)^p \leq (2 \max(|X|, |Y|))^p \\ &\leq 2^p \max(|X|^p, |Y|^p) \leq 2^p (|X|^p + |Y|^p) \end{aligned}$$

Por lo tanto,

$$E[|X + Y|^p] \leq 2^p (E[|X|^p] + E[|Y|^p]) < +\infty$$



## Algunas observaciones (2)

- 1 En consecuencia, el conjunto

$$L_d^p(\Omega, \mathcal{E}, P) = \{X : \Omega \rightarrow \overline{\mathbb{R}} \text{ variable aleatoria discreta} : E[|X|^p] < +\infty\}$$

(siendo  $\overline{\mathbb{R}} = \mathbb{R} \cup \{\pm\infty\}$ ) es un espacio vectorial.

- 2 Si  $p \geq 1$ , es posible probar que

$$\|X\|_p = E[|X|^p]^{\frac{1}{p}}$$

es una norma en dicho espacio.

En lo sucesivo, nos van a interesar especialmente dos clases  $L^p$ :

$$L_d^1(\Omega) = \{X : \Omega \rightarrow \overline{\mathbb{R}} : \text{variable aleatoria (discreta) con esperanza finita}\}$$

$$L_d^2(\Omega) = \{X : \Omega \rightarrow \overline{\mathbb{R}} : \text{variable aleatoria (discreta) con segundo momento finito}\}$$

# Un ejemplo

Notemos que  $L_d^2 \subset L_d^1$  por lo anterior. Veamos un ejemplo de una variable aleatoria que está en  $L_d^1$  pero no en  $L_d^2$ : Consideramos un espacio muestral numerable

$$\Omega = \{\omega_1, \omega_2, \dots, \omega_n, \dots\}$$

en el que

$$P\{\omega_n\} = \frac{1}{n(n+1)}$$

Verifiquemos que esta asignación efectivamente define una distribución de probabilidades en  $\Omega$ :

$$\sum_{n=1}^{\infty} P\{\omega_n\} = \sum_{n=1}^{\infty} \frac{1}{n(n+1)} = \sum_{n=1}^{\infty} \left[ \frac{1}{n} - \frac{1}{n+1} \right] = 1$$

(serie telescópica). Definamos la variable aleatoria  $X : \Omega \rightarrow \mathbb{R}$ , dada por  $X(\omega_n) = \sqrt{n}$ . Entonces,

$$E(X) = \sum_{n=1}^{\infty} X(\omega_n)P\{\omega_n\} = \sum_{n=1}^{\infty} \frac{\sqrt{n}}{n(n+1)} \leq \sum_{n=1}^{\infty} \frac{1}{n^{3/2}} < +\infty$$



## Un ejemplo (2)

pero

$$E(X^2) = \sum_{n=1}^{\infty} X(\omega_n)^2 P\{\omega_n\} = \sum_{n=1}^{\infty} \frac{n}{n(n+1)} = \sum_{n=1}^{\infty} \frac{1}{n+1} = +\infty$$

## Definición

El segundo momento de  $X$  entorno de su media se llama la **varianza** (o **variancia**<sup>a</sup>) de  $X$ , es decir:

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

Por lo anterior  $\text{Var}(X) < +\infty$  si y sólo si el segundo momento de  $X$  es finito, es decir si  $X \in L_d^2$ .

---

<sup>a</sup>Según el diccionario de la RAE, ambas gráficas son aceptables.

Como veremos la próxima clase, la varianza mide cuánto puede alejarse  $X$  de su esperanza o valor medio. Si  $\text{var}(X)$  es pequeña significa que la distribución de  $X$  está muy concentrada cerca de su esperanza. Es un **parámetro de dispersión**.

# Varianza de una indicadora

Sea  $A$  un evento con probabilidad  $p$ , e  $I_A$  su indicador. Calculemos su varianza. Ya vimos que:

$$E[I_A] = P(A) = p$$

En consecuencia:

$$\text{Var}(I_A) = E[(I_A - p)^2]$$

La distribución de probabilidades de  $(I_A - p)^2$  es:

$$(I_A - p)^2 = \begin{cases} (1 - p)^2 & \text{si ocurre } A \quad (\text{con probabilidad } p) \\ p^2 & \text{si no ocurre } A \quad (\text{con probabilidad } q = 1 - p) \end{cases}$$

En consecuencia,

$$\text{Var}(I_A) = (1 - p)^2 p + p^2(1 - p) = p - p^2 = pq$$

## Proposición

- 1 Si  $X = c$  es constante, entonces  $\text{Var}(X) = 0$ .
- 2  $\text{Var}(aX + b) = a^2 \text{Var}(X)$ .

## Demostración.

Si  $X = c$  es constante,  $E[X] = c$  luego  $\text{Var}(X) = E[0] = 0$ .

$$E[aX + b] = aE[X] + E[b] = a \cdot E[X] + b$$

$$\begin{aligned}\text{Var}(aX + b) &= E[((aX + b) - (a \cdot E[X] + b))^2] \\ &= E[(aX - aE(X))^2] = E[a^2(X - E(X))^2] = a^2 E[(X - E(X))^2] \\ &= a^2 \text{Var}(X)\end{aligned}$$

