

Repaso de Probabilidad

Germán Capdehourat, Sergio Martínez, Pablo Musé
{gcapde, sematag, pmuse}@fing.edu.uy

Instituto de Ingeniería Eléctrica
Facultad de Ingeniería



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY

4 de agosto de 2022

Desigualdades de Markov y Chebyshev

Convergencia de variables aleatorias

Teoremas límite

Probabilidades condicionales

Esperanza condicional

Desigualdad de Markov

- ▶ X VA tal que $\mathbb{E}[|X|] < \infty$, $a > 0$ constante
- ▶ Desigualdad de Markov: $P(|X| \geq a) \leq \frac{\mathbb{E}(|X|)}{a}$

Demostración.

- ▶ $\mathbb{I}\{|X| \geq a\} = 1$ si $|X| \geq a$, 0 si no.
Entonces (figura de la derecha)


$$a\mathbb{I}\{|X| \geq a\} \leq |X|$$

- ▶ Linealidad de la esperanza

$$a\mathbb{E}(\mathbb{I}\{|X| \geq a\}) \leq \mathbb{E}(|X|)$$

- ▶ Esperanza de función indicatriz = Probab. del suceso indicado

$$aP(|X| \geq a) \leq \mathbb{E}(|X|)$$



□

Desigualdad de Chebyshev

- ▶ X VA con $\mathbb{E}(X) = \mu$ y $\mathbb{E}[(X - \mu)^2] = \sigma^2$, $k > 0$ constante
- ▶ Desigualdad de Chebyshev: $P(|X - \mu| \geq k) \leq \frac{\sigma^2}{k^2}$

Demostración.

- ▶ Desigualdad de Markov para la VA $Z = (X - \mu)^2$ y $a = k^2$ constante

$$P((X - \mu)^2 \geq k^2) = P(|Z| \geq k^2) \leq \frac{\mathbb{E}[|Z|]}{k^2} = \frac{\mathbb{E}[(X - \mu)^2]}{k^2}$$

- ▶ Notar que $(X - \mu)^2 \geq k^2$ si y solo si $|X - \mu| \geq k$, entonces

$$P(|X - \mu| \geq k) \leq \frac{\mathbb{E}[(X - \mu)^2]}{k^2}$$

- ▶ La desigualdad de Chebyshev sigue de la definición de varianza



Convergencia de variables aleatorias

Desigualdades de Markov y Chebyshev

Convergencia de variables aleatorias

Teoremas límite

Probabilidades condicionales

Esperanza condicional

- ▶ Sea la sucesión de VAs $X_{\mathbb{N}} = X_1, X_2, \dots, X_n, \dots$

⇒ Distinguimos las VAs $X_{\mathbb{N}}$ de sus realizaciones $x_{\mathbb{N}}$

Q1) ¿Podemos decir algo sobre X_n para n grande? ⇒ No claro, X_n es VA

Q2) ¿Podemos decir algo sobre x_n para n grande? ⇒ Sí, $\lim_{n \rightarrow \infty} x_n$

Q3) ¿Podemos decir algo sobre $P(X_n \in \mathcal{X})$ para n grande? ⇒ Sí,
 $\lim_{n \rightarrow \infty} P(X_n \in \mathcal{X})$

- ▶ Queremos traducir lo que sabemos sobre límites convencionales a definiciones para VAs
- ▶ Comenzamos por la convergencia de la sucesión: $\lim_{n \rightarrow \infty} x_n$
⇒ **Convergencia segura y casi segura**
- ▶ Luego: **Convergencia en probabilidad, en media cuadrática y en distribución**

Convergencia de sucesiones y convergencia segura

- ▶ Denotemos como **sucesión de números** $x_{\mathbb{N}} = x_1, x_2, \dots, x_n, \dots$
- ▶ **Def:** La sucesión $x_{\mathbb{N}}$ **converge al valor** x si **dado** $\epsilon > 0$
 \Rightarrow **existe** n_0 tal que para todo $n > n_0$, $|x_n - x| < \epsilon$
- ▶ La sucesión x_n se acerca **arbitrariamente** a su límite $\Rightarrow |x_n - x| < \epsilon$
 \Rightarrow Además permanece cerca de su límite para todo $n > n_0$
- ▶ **Proceso estocástico (sucesión de VAs)** $X_{\mathbb{N}} = X_1, X_2, \dots, X_n, \dots$
 \Rightarrow Las realizaciones de $X_{\mathbb{N}}$ son sucesiones $x_{\mathbb{N}}$
- ▶ **Def:** Decimos que $X_{\mathbb{N}}$ **tiene convergencia segura a la VA** X si
 $\Rightarrow \lim_{n \rightarrow \infty} X_n = X$ para **toda realización** $x_{\mathbb{N}}$ of $X_{\mathbb{N}}$
- ▶ Dicho de otra manera, $\lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)$ para **todo** $\omega \in \Omega$
- ▶ **No es un criterio adecuado:** aún realizaciones (sin importancia) que suceden con probabilidad infinitamente pequeña impiden la convergencia segura

Convergencia casi segura

▶ Sean la VA X y el proceso estocástico $X_{\mathbb{N}} = X_1, X_2, \dots, X_n, \dots$

▶ **Def:** Decimos que $X_{\mathbb{N}}$ converge casi seguramente a la VA X si

$$P\left(\lim_{n \rightarrow \infty} X_n = X\right) = P\left(\{\omega : \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)\}\right) = 1$$

⇒ Casi todas las sucesiones convergen, a excepción de un conjunto de probabilidad nula

▶ Denotamos la convergencia casi segura por $\Rightarrow \lim_{n \rightarrow \infty} X_n = X$ c.s.

⇒ El límite X es una VA


Ejemplo

▶ $X_0 \sim \mathcal{N}(0, 1)$ (normal, media 0, varianza 1)

▶ Z_n sucesión de VAs de Bernoulli de parámetro p

▶ Definimos $\Rightarrow X_n = X_0 - \frac{Z_n}{n}$

▶ $\frac{Z_n}{n} \rightarrow 0$ por lo que $\lim_{n \rightarrow \infty} X_n = X_0$ c.s.
(también seguramente)



Ejemplo de convergencia casi segura

- ▶ Consideremos $\Omega = [0, 1]$ y sea $P(\cdot)$ la distribución uniforme
 $\Rightarrow P([a, b]) = b - a, 0 \leq a \leq b \leq 1$
- ▶ Definimos las VAs $X_n(\omega) = \omega + \omega^n$ y $X(\omega) = \omega$
- ▶ Para todo $\omega \in [0, 1)$ $\Rightarrow \omega^n \rightarrow 0$ para $n \rightarrow \infty$, de donde $X_n(\omega) \rightarrow \omega = X(\omega)$
- ▶ Para $\omega = 1$ $\Rightarrow X_n(1) = 2$ para todo n , mientras que $X(1) = 1$
- ▶ La convergencia ocurre únicamente en el conjunto $[0, 1)$, y $P([0, 1)) = 1$
 - \Rightarrow Decimos que $\lim_{n \rightarrow \infty} X_n = X$ c.s.
 - \Rightarrow Una vez más, nótese que el límite X es una VA

Convergencia en probabilidad

- ▶ **Def:** Decimos que X_N converge en probabilidad a la VA X si para todo $\epsilon > 0$

$$\lim_{n \rightarrow \infty} P(|X_n - X| < \epsilon) = \lim_{n \rightarrow \infty} P(\{\omega \in \Omega : |X_n(\omega) - X(\omega)| < \epsilon\}) = 1$$

⇒ La probabilidad que $|X_n - X|$ se vuelva menor a ϵ tiende a 1

- ▶ La afirmación es sobre probabilidades, no sobre realizaciones
⇒ Si hay convergencia en probabilidad, las realizaciones x_N pueden o no converger

Teorema

La convergencia casi segura (c.s.) implica la convergencia en probabilidad

Demostración.

Si $\lim_{n \rightarrow \infty} X_n = X$ c.s. entonces dado $\epsilon > 0$, para todo $\omega \in \Omega$ salvo un conjunto de probabilidad nula, existe $n = n(\epsilon, \omega)$ tal que $|X_k(\omega) - X(\omega)| < \epsilon$ para todo $k \geq n$. Es decir, $P(\bigcup_{n=1}^{\infty} \bigcap_{k=n}^{\infty} |X_k(\omega) - X(\omega)| < \epsilon) = 1$. Tomando el complemento,


$P(\bigcap_{n=1}^{\infty} \bigcup_{k=n}^{\infty} |X_k(\omega) - X(\omega)| \geq \epsilon) = 0 \Rightarrow$ como los $E_n = \{\bigcup_{k=n}^{\infty} |X_k(\omega) - X(\omega)| \geq \epsilon\}$ verifican $E_1 \supset E_2 \supset \dots$, entonces $\lim_{n \rightarrow \infty} P(E_n) = P(\bigcap_{n=1}^{\infty} E_n) = 0$. De aquí se obtiene que $P(|X_n - X| \geq \epsilon) \leq P(\bigcup_{k=n}^{\infty} |X_k - X| \geq \epsilon) = P(E_n) \rightarrow 0$ si $n \rightarrow \infty$. \square

Ejemplo de convergencia en probabilidad

- ▶ $X_0 \sim \mathcal{N}(0, 1)$
- ▶ Z_n sucesión de VAs Bernoulli, **parámetro $1/n$**
- ▶ Definimos $\Rightarrow X_n = X_0 - Z_n$
- ▶ X_n converge en probabilidad a X_0 ya que

$$\begin{aligned} P(|X_n - X_0| < \epsilon) &= P(|Z_n| < \epsilon) \\ &= 1 - P(Z_n = 1) \\ &= 1 - \frac{1}{n} \rightarrow 1 \end{aligned}$$

- ▶ Gráficas: realizaciones de x_n hasta to $n = 10^2$,
 $n = 10^3$, $n = 10^4$
 $\Rightarrow Z_n = 1$ se vuelve raro pero igual sucede



Diferencia entre convergencia c.s. y en probabilidad

- ▶ La convergencia c.s. implica que **casi todas las secuencias convergen**
- ▶ La convergencia en probabilidad **no implica la convergencia de las sucesiones**
- ▶ Ejemplo anterior: $X_n = X_0 - Z_n$, Z_n Bernoulli de parámetro $1/n$
⇒ Mostramos que converge en probabilidad

$$P(|X_n - X_0| < \epsilon) = 1 - \frac{1}{n} \rightarrow 1$$

⇒ Pero para casi todas las sucesiones, $\lim_{n \rightarrow \infty} x_n$ no existe

- ▶ Convergencia casi segura ⇒ **las perturbaciones dejan de suceder**
- ▶ Convergencia en probabilidad ⇒ **las perturbaciones suceden, pero su frecuencia tiende a cero**

Convergencia en r -media

Def: Supongamos que las X_N tienen momento de orden $r \geq 1$ finito. Decimos que X_N converge en r -media a la VA X si

$$\lim_{n \rightarrow \infty} \mathbb{E}[|X_n - X|^r] = 0$$

- ▶ $r = 1$: conv. en media; $r = 2$: conv. en media cuadrática (m.c.)
- ▶ A veces es (muy) fácil de comprobar
- ▶ Es fácil ver que si $r > s \geq 1$: conv. en s -media \Rightarrow conv. en r -media

Teorema

La convergencia en r -media implica la convergencia en probabilidad

Demostración.

- ▶ De la desigualdad de Markov

$$P(|X_n - X| \geq \epsilon) = P(|X_n - X|^r \geq \epsilon^r) \leq \frac{\mathbb{E}[|X_n - X|^r]}{\epsilon^r}$$

- ▶ Si $X_n \rightarrow X$ en r -media, $\mathbb{E}[|X_n - X|^r]/\epsilon^r \rightarrow 0$ para todo $\epsilon > 0$



- ▶ Convergencia casi segura y en r -media: **ninguna implica la otra**
- ▶ Ejemplo (convergencia c.s y no en media):

$$X_n = \begin{cases} n^3 & \text{con probabilidad } 1/n^2, \\ 0 & \text{con probabilidad } 1 - 1/n^2. \end{cases}$$


- ▶ Ejemplo (convergencia en media y no c.s.): X_n Bernoulli de parámetro $1/n$.

Convergencia en distribución

- ▶ Consideremos el proceso estocástico $X_{\mathbb{N}}$. La cdf de X_n es $F_n(x)$
- ▶ **Def:** decimos que $X_{\mathbb{N}}$ **converge en distribución** a la VA X con cdf $F_X(x)$ si
 - ⇒ $\lim_{n \rightarrow \infty} F_n(x) = F_X(x)$ para todo x en el que $F_X(x)$ es continua
- ▶ No se afirma nada sobre las sucesiones individualmente, sólo sobre la cdf de X_n
 - ⇒ Es la **convergencia más débil** entre las que vimos
- ▶ Las convergencias c.s., en probabilidad y en r -media implican convergencia en distribución


Ejemplo

- ▶ $Y_n \sim \mathcal{N}(0, 1)$
- ▶ Z_n Bernoulli de parámetro p
- ▶ Definimos ⇒ $X_n = Y_n - Z_n/n$
- ▶ $\frac{Z_n}{n} \rightarrow 0 \Rightarrow \lim_{n \rightarrow \infty} F_n(x) = \mathcal{N}(0, 1)$



Relaciones de implicancia

- ▶ Segura \Rightarrow casi segura \Rightarrow en probabilidad \Rightarrow en distribución
- ▶ En r -media \Rightarrow en probabilidad \Rightarrow en distribución



Desigualdades de Markov y Chebyshev

Convergencia de variables aleatorias

Teoremas límite

Probabilidades condicionales

Esperanza condicional

Ley de los grandes números

- ▶ $X_1, X_2, \dots, X_n, \dots$ sucesión de VAs i.i.d. de media μ
- ▶ Definimos la media muestral como $\bar{X}_N := (1/N) \sum_{n=1}^N X_n$

Teorema (Ley débil de los grandes números)

La media muestral \bar{X}_N de la sucesión i.i.d. **converge en prob.** a $\mu = \mathbb{E}[X_n]$

$$\lim_{N \rightarrow \infty} \mathbb{P}(|\bar{X}_N - \mu| < \epsilon) = 1, \quad \text{for all } \epsilon > 0$$

Teorema (Ley fuerte de los grandes números)

La media muestral \bar{X}_N de la sucesión i.i.d. **converge c.s.** a $\mu = \mathbb{E}[X_n]$

$$\mathbb{P}\left(\lim_{N \rightarrow \infty} \bar{X}_N = \mu\right) = 1$$

- ▶ La ley fuerte implica la ley débil

Teorema central del límite (TCL)

Teorema (Teorema central del límite)

Sea $X_1, X_2, \dots, X_n, \dots$ una sucesión de VAs i.i.d. de media $\mathbb{E}[X_n] = \mu$ y varianza $\mathbb{E}[(X_n - \mu)^2] = \sigma^2$ para todo n . Entonces

$$\lim_{N \rightarrow \infty} \mathbb{P} \left(\frac{\sum_{n=1}^N X_n - N\mu}{\sigma\sqrt{N}} \leq x \right) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-u^2/2} du$$

- Esto significa que para N suficientemente grande,

$$Z_N := \frac{\sum_{n=1}^N X_n - N\mu}{\sigma\sqrt{N}} \sim \mathcal{N}(0, 1)$$

⇒ Z_N converge en distribución a una VA normal estándar

⇒ **Universalidad notable!** La distribución de los X_n es arbitraria

Teorema central del límite (TCL) (cont.)

- ▶ Equivale a decir que $\Rightarrow \sum_{n=1}^N X_n \sim \mathcal{N}(N\mu, N\sigma^2)$
- ▶ La suma de un gran número de VAs i.i.d. tiene distribución normal
 - \Rightarrow Aquí tomar límite no tiene sentido
 - \Rightarrow Pero intuitivamente, esto es lo que dice el TCL

Ejemplo

- ▶ X VA binomial de parámetros (n, p)
- ▶ Escribimos $X = \sum_{i=1}^n X_i$ con X_i VAs Bernoulli de parámetro p , i.i.d.
- ▶ Media $\mathbb{E}[X_i] = p$, varianza $\text{var}[X_i] = p(1-p)$
 - \Rightarrow Para n suficientemente grande $\Rightarrow X \sim \mathcal{N}(np, np(1-p))$

Desigualdades de Markov y Chebyshev

Convergencia de variables aleatorias

Teoremas límite

Probabilidades condicionales

Esperanza condicional

pmf y cdf condicionales para VAs discretas

- ▶ Recordemos la definición de probabilidad condicional para sucesos E y F

$$P(E | F) = \frac{P(E \cap F)}{P(F)}$$

- ▶ **Def:** La pmf condicional de la VA X dada Y , ambas discretas, es

$$p_{X|Y}(x | y) = P(X = x | Y = y) = \frac{P(X = x, Y = y)}{P(Y = y)}$$

- ▶ Se puede reescribir como

$$p_{X|Y}(x | y) = \frac{P(X = x, Y = y)}{P(Y = y)} = \frac{p_{XY}(x, y)}{p_Y(y)}$$

⇒ pmf de la VA X , dado el parámetro y (“ Y no es más aleatoria”, tomó el valor y)

- ▶ **Def:** La cdf condicional es (un rango de X condicionado a un valor of Y)

$$F_{X|Y}(x | y) = P(X \leq x | Y = y) = \sum_{z \leq x} p_{X|Y}(z | y)$$

- ▶ **Def:** La pdf condicional de X dado Y , ambas continuas, es

$$f_{X|Y}(x|y) = \frac{f_{XY}(x,y)}{f_Y(y)}$$

- ▶ A modo de motivación, definamos los intervalos $\Delta x = [x, x+dx]$ y $\Delta y = [y, y+dy]$

⇒ Aproximamos la prob. condicional $P(X \in \Delta x | Y \in \Delta y)$:

$$P(X \in \Delta x | Y \in \Delta y) = \frac{P(X \in \Delta x, Y \in \Delta y)}{P(Y \in \Delta y)} \approx \frac{f_{XY}(x,y)dx dy}{f_Y(y)dy}$$

- ▶ De la definición de pdf condicional surge que

$$P(X \in \Delta x | Y \in \Delta y) \approx f_{X|Y}(x|y)dx$$

⇒ Es lo que esperamos de una densidad

- ▶ **Def:** La cdf condicional es ⇒ $F_{X|Y}(x) = \int_{-\infty}^x f_{X|Y}(u|y)du$

Ejemplo: modelo simple de canal de comunicación

- ▶ Mensaje aleatorio (VA) Y , transmitimos la señal y (realización de Y)
- ▶ La señal recibida es $x = y + z$ (z realización de ruido aleatorio)
 - ⇒ Modelamos un **sistema de comunicación** como la relación entre VAs

$$X = Y + Z$$

⇒ Modelamos el ruido aditivo como $Z \sim \mathcal{N}(0, \sigma^2)$, independiente de Y

- ▶ **Q:** ¿Cómo es la pdf condicional de X dado Y ? Probemos con la definición

$$f_{X|Y}(x|y) = \frac{f_{XY}(x, y)}{f_Y(y)} = \frac{?}{f_Y(y)}$$

⇒ El problema es que no conocemos $f_{XY}(x, y)$. **Debemos calcularla**

- ▶ **En general es más fácil calcular o estimar probabilidades condicionales que conjuntas**

Ejemplo: modelo simple de canal de comunicación (cont.)

- ▶ Si $Y = y$ está dado, entonces “ Y no es más aleatoria”
 - ⇒ En realidad sigue siendo aleatoria, pero la pensamos como dada
- ▶ Si Y no fuese aleatoria, digamos $Y = y$ con y dada por $X = y + Z$
 - ⇒ La cdf de X dado $Y = y$ ahora es fácil (usamos independencia de Y y Z)

$$P(X \leq x | Y = y) = P(y + Z \leq x | Y = y) = P(Z \leq x - y)$$

- ▶ Pero como Z es normal de media nula y varianza σ^2

$$\begin{aligned} P(X \leq x | Y = y) &= \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{x-y} e^{-z^2/2\sigma^2} dz \\ &= \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^x e^{-(z-y)^2/2\sigma^2} dz \end{aligned}$$

⇒ $[X \text{ dado } Y = y]$ es normal de media y y varianza σ^2

Desigualdades de Markov y Chebyshev

Convergencia de variables aleatorias

Teoremas límite

Probabilidades condicionales

Esperanza condicional

Definición de esperanza condicional

- ▶ **Def:** Para las VAs continuas X e Y , la **esperanza condicional** es

$$\mathbb{E}[X | Y = y] = \int_{-\infty}^{\infty} x f_{X|Y}(x|y) dx$$

- ▶ **Def:** Para las VAs discretas X , Y , la esperanza condicional es

$$\mathbb{E}[X | Y = y] = \sum_x x p_{X|Y}(x|y)$$

- ▶ Definida para un y dado $\Rightarrow \mathbb{E}[X | Y = y]$ es un número
 \Rightarrow Si consideramos que Y tomar valores $y \Rightarrow \mathbb{E}[X | Y]$ es VA
- ▶ $\mathbb{E}[X | Y]$ es una función de la VA Y , por lo tanto es una VA
 $\Rightarrow \mathbb{E}[X | Y = y]$ valor asociado a la realización $Y = y$
- ▶ Si X e Y son **independientes**, entonces $\mathbb{E}[X | Y] = \mathbb{E}[X]$

- ▶ Como $\mathbb{E}[X | Y]$ es VA, podemos calcular su valor esperado $\mathbb{E}_Y[\mathbb{E}_X[X | Y]]$. Los subíndices especifican la variable sobre la que se calcula la esperanza
- ▶ Q: ¿Cuánto vale $\mathbb{E}_Y[\mathbb{E}_X[X | Y]]$? $\Rightarrow \mathbb{E}[X] = \mathbb{E}_Y[\mathbb{E}_X[X | Y]]$ (razonable)
- ▶ Lo demostramos para VAs discretas (VAs continuas, usar integrales)

$$\begin{aligned}\mathbb{E}_Y[\mathbb{E}_X[X | Y]] &= \sum_y \mathbb{E}_X[X | Y = y] p_Y(y) = \sum_y \left[\sum_x x p_{X|Y}(x|y) \right] p_Y(y) \\ &= \sum_x x \left[\sum_y p_{X|Y}(x|y) p_Y(y) \right] = \sum_x x \left[\sum_y p_{XY}(x, y) \right] \\ &= \sum_x x p_X(x) = \mathbb{E}[X]\end{aligned}$$

- ▶ Ofrece un método útil para calcular valores esperados

\Rightarrow Condicionar por $Y = y$

\Rightarrow Calcular valor esperado sobre X dado $Y = y$

\Rightarrow Calcular valor esperado sobre todos los y de Y

$\Rightarrow X | Y = y$

$\Rightarrow \mathbb{E}_X[X | Y = y]$

$\Rightarrow \mathbb{E}_Y[\mathbb{E}_X[X | Y]]$