

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

5 de agosto de 2021

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: $P(|X| \geq a) \leq \frac{\mathbb{E}(|X|)}{a}$

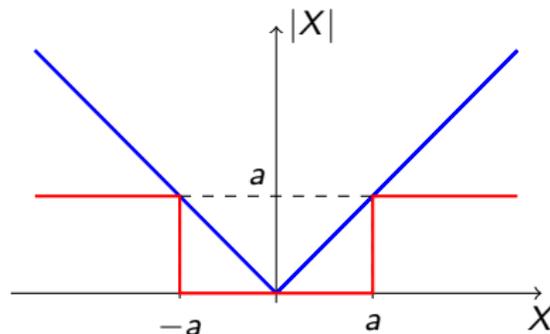
Demostración.

- ▶ $\mathbb{I}\{|X| \geq a\} = 1$ 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



- ▶ Si el valor absoluto esperado es finito, i.e., $\mathbb{E}[|X|] < \infty$
 - ⇒ La cdf complementaria (ccdf) $P(|X| \geq x)$ decae al menos como x^{-1} (Markov)
- ▶ Si la media $\mathbb{E}(X)$ y la varianza $\mathbb{E}[(X - \mu)^2]$ son finitas
 - ⇒ La ccdf decrece al menos como x^{-2} (Chebyshev)
- ▶ La mayor parte de las ccdfs decrecen exponencialmente (e.g. e^{-x^2} para normales)
 - ⇒ Las cotas $\propto x^{-\alpha}$ son débiles pero pueden ser útiles
- ▶ Muchas veces la desigualdad de Markov se utiliza para VAs no negativas $X \geq 0$
 - ⇒ Podemos dejar de lado el valor absoluto: $P(X \geq a) \leq \frac{\mathbb{E}(X)}{a}$
 - ⇒ Cota general: $P(X \geq a) \leq \frac{\mathbb{E}(X^r)}{a^r}$ para cualquier $r > 0$

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** $x_{\mathbb{N}}$ de $X_{\mathbb{N}}$
- ▶ 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

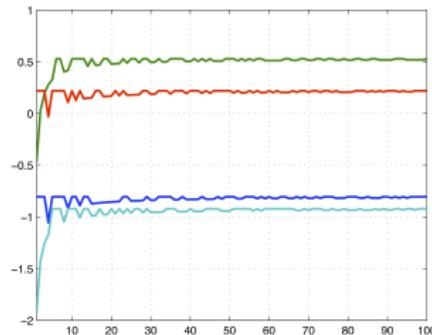
Ejemplo

▶ $X_0 \sim \mathcal{N}(0, 1)$ (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,

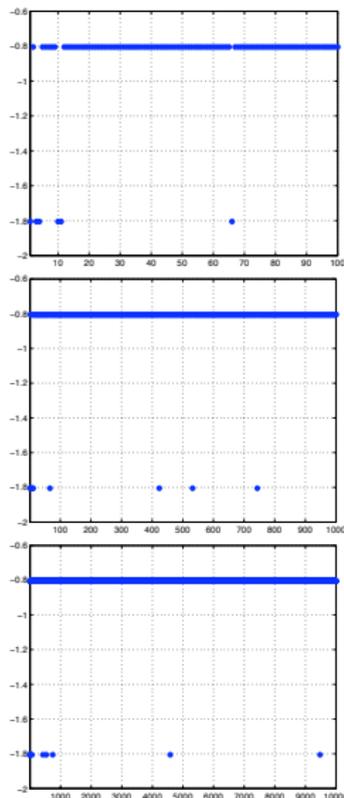
$P(\bigcap_{n=1}^{\infty} \bigcup_{k=n}^{\infty} |X_k(\omega) - X(\omega)| \geq \epsilon) = 0 \Rightarrow$ como los $E_n = \{\bigcup_{k=n}^{\infty} |X_k(\omega) - X(\omega)| \geq \epsilon\}$ verifican $E_1 \supset E_2 \supset \dots$, entonces $\lim_{n \rightarrow \infty} P(E_n) = P(\bigcap_{n=1}^{\infty} E_n) = 0$. 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**
- ▶ **La diferencia no es menor**
 - ▶ Interpretemos Z_n como la tasa de cambios en los ahorros
 - ▶ Con la convergencia c.s. **el riesgo se elimina**
 - ▶ Con la convergencia en prob. **el riesgo decrece pero no desaparece**

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):

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

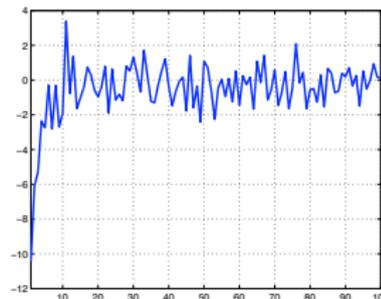
- ▶ Ejemplo (convergencia en media y no c.s.): X_n Bernoulli de parámetro $1/n$.

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
 - $\Rightarrow \lim_{n \rightarrow \infty} F_n(x) = F_X(x)$ 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
 - \Rightarrow Es la **convergencia más débil** entre las que vimos
- ▶ Las convergencias c.s., en probabilidad y en r -media implican convergencia en distribución

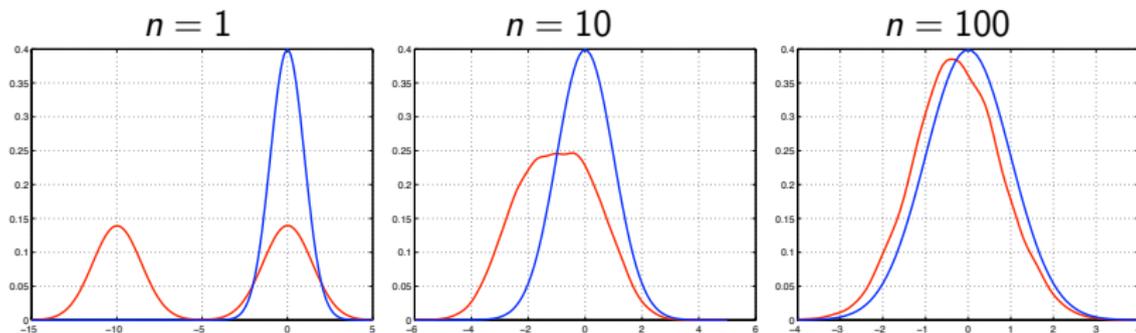
Ejemplo

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



Convergencia en distribución (cont.)

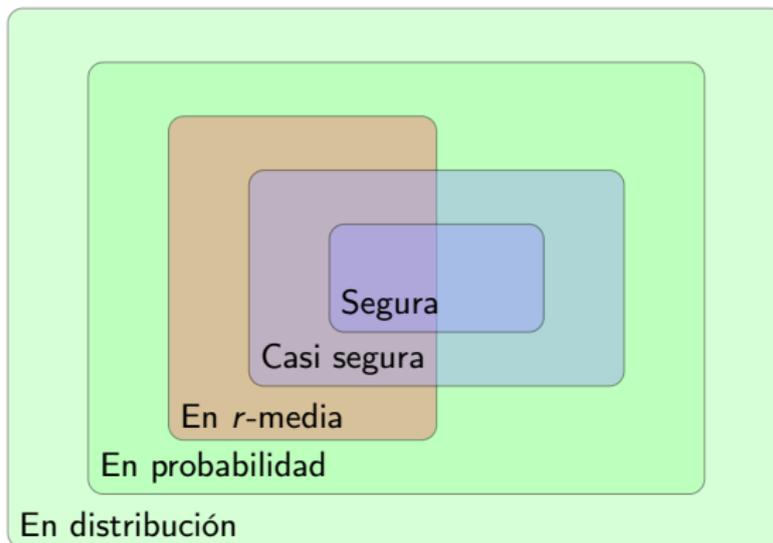
- ▶ Las sucesiones individuales x_n no convergen en ningún sentido
⇒ Es la función de distribución quien converge



- ▶ A medida que el efecto de Z_n/n disminuye, la pdf de X_n converge a la pdf de Y_n
⇒ Normal estándar $\mathcal{N}(0, 1)$

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

Suma de VAs independientes e idénticamente distribuídas

- ▶ $X_1, X_2, \dots, X_n, \dots$ VAs **independientes, idénticamente distribuídas** (i.i.d.)
- ▶ Media $\mathbb{E}[X_n] = \mu$ y varianza $\mathbb{E}[(X_n - \mu)^2] = \sigma^2$ para tod n
- ▶ **Q:** ¿Qué sucede con la suma $S_N := \sum_{n=1}^N X_n$ cuando N crece?
- ▶ El valor esperado de la suma es $\mathbb{E}[S_N] = N\mu \Rightarrow$ Diverge si $\mu \neq 0$
- ▶ La varianza es $\mathbb{E}[(S_N - N\mu)^2] = N\sigma^2 \Rightarrow$ Diverge si $\sigma \neq 0$
- ▶ Una normalización interesantes es $\Rightarrow \bar{X}_N := (1/N) \sum_{n=1}^N X_n$
- ▶ Con esto $\mathbb{E}[\bar{X}_N] = \mu$ y $\text{var}[\bar{X}_N] = \sigma^2/N$
 - \Rightarrow **Ley de los grandes números** (débil y fuerte)
- ▶ Otra normalización interesante es $\Rightarrow Z_N := \frac{\sum_{n=1}^N X_n - N\mu}{\sigma\sqrt{N}}$
- ▶ Con esto $\mathbb{E}[Z_N] = 0$ and $\text{var}[Z_N] = 1$ para todo N
 - \Rightarrow **Teorema central del límite**

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

Prueba de la ley débil de los grandes números

- ▶ La ley **débil** de los grandes números es muy fácil de demostrar

Demostración.

- ▶ La varianza de \bar{X}_N se decae a cero para N grande

$$\text{var} [\bar{X}_N] = \frac{1}{N^2} \sum_{n=1}^N \text{var} [X_n] = \frac{\sigma^2}{N} \rightarrow 0$$

- ▶ Como

$$0 \leftarrow \frac{\sigma^2}{N} = \text{var} [\bar{X}_N] = \mathbb{E} [(\bar{X}_N - \mu)^2]$$

tenemos que \bar{X}_N converge a μ en media cuadrática

\Rightarrow Entonces \bar{X}_N converge a μ en probabilidad □

- ▶ La ley **fuerte** es más difícil de demostrar (no lo haremos aquí)

- ▶ **Serie de experimentos** \Rightarrow Sucesión de VAs $X_1, X_2, \dots, X_n, \dots$
 - \Rightarrow Consideramos un suceso de interés $X \in E$. Ej: obtener “cara” al tirar una moneda
- ▶ La fracción de veces que $X \in E$ sucede en N experimentos es

$$\bar{X}_N = \frac{1}{N} \sum_{n=1}^N \mathbb{I}\{X_n \in E\}$$

- ▶ Como las indicatrices son también i.i.d., la ley fuerte asegura que

$$\lim_{N \rightarrow \infty} \bar{X}_N = \mathbb{E}[\mathbb{I}\{X_1 \in E\}] = \mathbf{P}(X_1 \in E) \quad a.s.$$

- ▶ La ley fuerte coincide con nuestra noción intuitiva de probabilidad
 - \Rightarrow **Frecuencia relativa de ocurrencia de un suceso en varios experimentos**
 - \Rightarrow Justifica los procedimientos de estimación basados en simulaciones (e.g. histogramas)

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)

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

Ejemplo de pmf condicional

- ▶ Consideremos las VAs Bernoulli independientes Y y Z . Definimos $X = Y + Z$
- ▶ **Q:** ¿pmf condicional de X dado Y ? Para $X = 0, Y = 0$

$$p_{X|Y}(X = 0 | Y = 0) = \frac{P(X = 0, Y = 0)}{P(Y = 0)} = \frac{(1-p)^2}{1-p} = 1-p$$

- ▶ También la podemos obtener de las pmfs conjunta y marginal

$$p_{X|Y}(X = 0 | Y = 0) = \frac{p_{XY}(0,0)}{p_Y(0)} = \frac{(1-p)^2}{1-p} = 1-p$$

- ▶ Podemos calcular el resto de forma análoga

$$\begin{aligned} p_{X|Y}(0|0) &= 1-p, & p_{X|Y}(1|0) &= p, & p_{X|Y}(2|0) &= 0 \\ p_{X|Y}(0|1) &= 0, & p_{X|Y}(1|1) &= 1-p, & p_{X|Y}(2|1) &= p \end{aligned}$$

Condicionamiento de una suma de VAs Poisson

- ▶ Sean Y, Z VAs de Poisson independientes, de parámetros λ_1 y λ_2
- ▶ Definimos $X = Y + Z$. **Q:** ¿pmf condicional de Y dado X ?

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

- ▶ Usamos independencia de Y y Z . Ahora recordemos que X es Poisson de parámetro $\lambda = \lambda_1 + \lambda_2$

$$\begin{aligned} p_{Y|X}(Y = y | X = x) &= \frac{e^{-\lambda_1} \lambda_1^y}{y!} \frac{e^{-\lambda_2} \lambda_2^{x-y}}{(x-y)!} \left[\frac{e^{-(\lambda_1 + \lambda_2)} (\lambda_1 + \lambda_2)^x}{x!} \right]^{-1} \\ &= \frac{x!}{y!(x-y)!} \frac{\lambda_1^y \lambda_2^{x-y}}{(\lambda_1 + \lambda_2)^x} \\ &= \binom{x}{y} \left(\frac{\lambda_1}{\lambda_1 + \lambda_2} \right)^y \left(\frac{\lambda_2}{\lambda_1 + \lambda_2} \right)^{x-y} \end{aligned}$$

⇒ Condicionada a $X = x$, Y es **binomial** $(x, \lambda_1/(\lambda_1 + \lambda_2))$

- ▶ **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

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

- ▶ El condicionamiento es una herramienta usual para estimar probabilidades

- ▶ Mensaje 1 (con probabilidad p)

⇒ Transmiso $Y = 1$

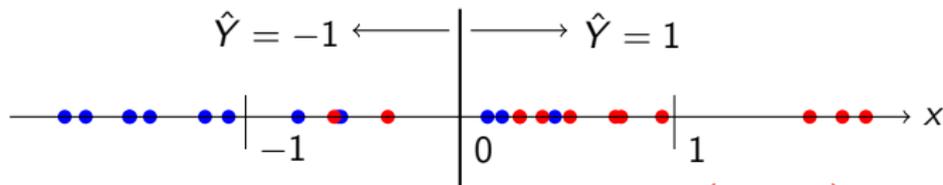
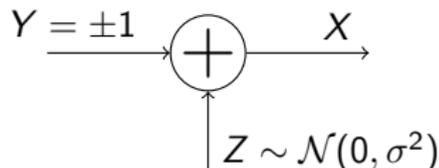
- ▶ Message 2 (con probabilidad q)

⇒ Transmiso $Y = -1$

- ▶ Señal recibida ⇒ $X = Y + Z$

- ▶ Regla de decisión: ⇒ $\hat{Y} = 1$ si $X \geq 0$, $\hat{Y} = -1$ si $X < 0$

⇒ **Errores:** ● a la izquierda de 0 y ● a la derecha de 0



- ▶ Q: ¿Cuál es la probabilidad de error, $P_e := P(\hat{Y} \neq Y)$?

Modelo simple de canal de comunicación (cont.)

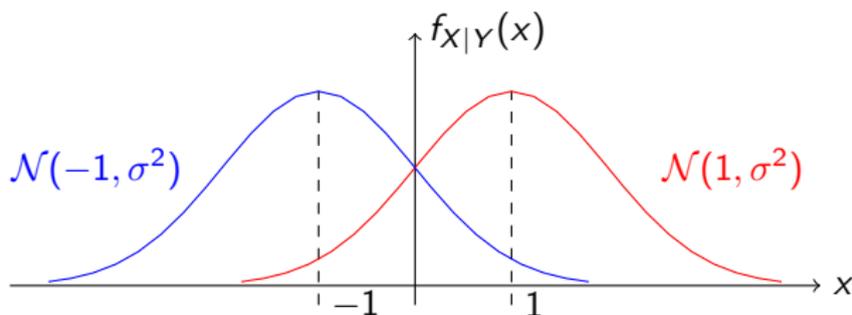
► pdf de la salida: sabemos que

⇒ Si $Y = 1$ entonces $X | Y = 1 \sim \mathcal{N}(1, \sigma^2)$. La pdf condicional es

$$f_{X|Y}(x | 1) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(x-1)^2/2\sigma^2}$$

⇒ Si $Y = -1$ entonces $X | Y = -1 \sim \mathcal{N}(-1, \sigma^2)$. La pdf condicional es

$$f_{X|Y}(x | -1) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(x+1)^2/2\sigma^2}$$



Modelo simple de canal de comunicación (cont.)

- **Probabilidad de error:** la escribimos condicionando en $Y = \pm 1$ (prob. total)

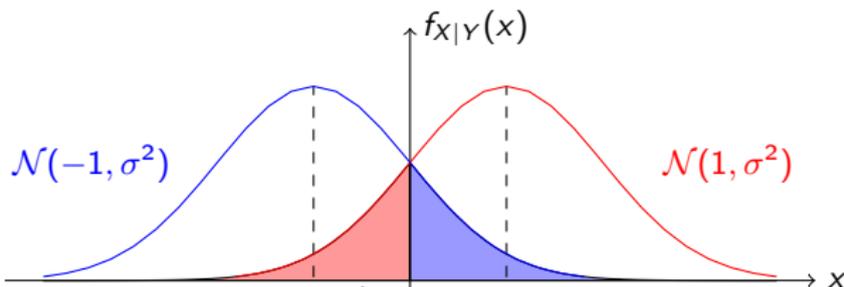
$$P_e = P(\hat{Y} \neq Y | Y = 1) P(Y = 1) + P(\hat{Y} \neq Y | Y = -1) P(Y = -1) \\ = P(\hat{Y} = -1 | Y = 1) p + P(\hat{Y} = 1 | Y = -1) q$$

- De acuerdo a la regla de decisión

$$P_e = P(X < 0 | Y = 1) p + P(X \geq 0 | Y = -1) q$$

- Como X dado Y es normal, tenemos

$$P_e = \frac{p}{\sqrt{2\pi}\sigma} \int_{-\infty}^0 e^{-(x-1)^2/2\sigma^2} dx + \frac{q}{\sqrt{2\pi}\sigma} \int_0^{\infty} e^{-(x+1)^2/2\sigma^2} dx$$



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

Ejemplo de esperanza condicional

- ▶ Sean Y y Z VAs de Bernoulli independientes, definimos $X = Y + Z$
- ▶ **Q:** ¿Cuánto vale $\mathbb{E}[X | Y = 0]$? Recordemos que encontramos la pmf condicional

$$\begin{aligned} p_{X|Y}(0|0) &= 1 - p, & p_{X|Y}(1|0) &= p, & p_{X|Y}(2|0) &= 0 \\ p_{X|Y}(0|1) &= 0, & p_{X|Y}(1|1) &= 1 - p, & p_{X|Y}(2|1) &= p \end{aligned}$$

- ▶ Usando la definición de esperanza condicional para variables discretas

$$\begin{aligned} \mathbb{E}[X | Y = 0] &= \sum_x x p_{X|Y}(x|0) \\ &= 0 \times (1 - p) + 1 \times p + 2 \times 0 = p \end{aligned}$$

- ▶ 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

$\Rightarrow X | Y = y$

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

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

Ejemplo de esperanzas iteradas

- ▶ Consideremos un curso de probabilidad en alguna universidad
 - ⇒ Avanzados aprueban con $A = 4$ (prob. 0,5), $B = 3$ (prob. 0,5)
 - ⇒ Principiantes con $B = 3$ (prob. 0,6), $C = 2$ (prob. 0,4)
 - ⇒ Un estudiante de intercambio es avanzado con prob. 0,7, y principiante con prob. 0,3
- ▶ Q: ¿Valor esperado de $X =$ nota del estudiante de intercambio?
- ▶ Comenzamos por condicionar en grado de avance en la carrera

$$\mathbb{E}[X \mid \text{Avanzado}] = 0,5 \times 4 + 0,5 \times 3 = 3,5$$

$$\mathbb{E}[X \mid \text{Ppte}] = 0,6 \times 3 + 0,4 \times 2 = 2,6$$

- ▶ Sumamos sobre las probabilidades de grado de avance

$$\begin{aligned}\mathbb{E}[X] &= \mathbb{E}[X \mid \text{Avanzado}] P(\text{Avanzado}) + \mathbb{E}[X \mid \text{Ppte}] P(\text{Ppte}) \\ &= 3,5 \times 0,7 + 2,6 \times 0,3 = 3,23\end{aligned}$$

Condicionamiento en una suma de VAs de Poisson

- ▶ Y, Z VAs de Poisson independientes, de parámetros λ_1, λ_2
- ▶ Definimos $X = Y + Z$. ¿Cuánto vale $\mathbb{E}[Y | X = x]$?
 - ⇒ Vimos que $Y | X = x$ es **binomial** ($x, \lambda_1/(\lambda_1 + \lambda_2)$), por lo que

$$\mathbb{E}[Y | X = x] = \frac{x\lambda_1}{\lambda_1 + \lambda_2}$$

- ▶ Ahora usamos esperanzas iteradas para calcular $\mathbb{E}[Y]$
 - ⇒ Recordemos que X es Poisson con parámetro $\lambda = \lambda_1 + \lambda_2$

$$\begin{aligned}\mathbb{E}[Y] &= \sum_{x=0}^{\infty} \mathbb{E}[Y | X = x] p_X(x) = \sum_{x=0}^{\infty} \frac{x\lambda_1}{\lambda_1 + \lambda_2} p_X(x) \\ &= \frac{\lambda_1}{\lambda_1 + \lambda_2} \mathbb{E}[X] = \frac{\lambda_1}{\lambda_1 + \lambda_2} (\lambda_1 + \lambda_2) = \lambda_1\end{aligned}$$

- ▶ Obviamente, ya que Y es Poisson con parámetro λ_1

Condicionamiento para cálculo de esperanzas

- ▶ Como para las probabilidades, condicionar es útil para calcular esperanzas

⇒ Reduce la dificultad a problemas más simples

Ejemplo

- ▶ Un jugador de baseball anota X_i carreras por partido
⇒ Número esperado de carreras: $\mathbb{E}[X_i] = \mathbb{E}[X]$, indep. del partido

- ▶ El jugador juega N partidos por temporada, N aleatorio
⇒ Número esperado de partidos: $\mathbb{E}[N]$

- ▶ ¿Cuál es el número esperado de carreras en la temporada?

$$\Rightarrow \mathbb{E}\left[\sum_{i=1}^N X_i\right]$$

- ▶ Tanto N como X_i son aleatorios. Aquí las suponemos independientes
⇒ La suma $\sum_{i=1}^N X_i$ se conoce como **VA compuesta**

Suma de un número aleatorio de variables aleatorias

Paso 1: Condicionamiento por $N = n$

$$\left[\sum_{i=1}^N X_i \mid N = n \right] = \sum_{i=1}^n X_i$$

Paso 2: Calcular el valor esperado con respecto a X_i , usando la independencia de N y X_i

$$\mathbb{E}_{X_i} \left[\sum_{i=1}^N X_i \mid N = n \right] = \mathbb{E}_{X_i} \left[\sum_{i=1}^n X_i \mid N = n \right] = \mathbb{E}_{X_i} \left[\sum_{i=1}^n X_i \right] = n \mathbb{E}[X]$$

⇒ La tercer igualdad es posible porque n es determinístico

Paso 3: Calcular el valor esperado con respecto a los valores n de N

$$\mathbb{E}_N \left[\mathbb{E}_{X_i} \left[\sum_{i=1}^N X_i \mid N \right] \right] = \mathbb{E}_N [N \mathbb{E}[X]] = \mathbb{E}[N] \mathbb{E}[X]$$

Se obtiene el resultado ⇒ $\mathbb{E} \left[\sum_{i=1}^N X_i \right] = \mathbb{E}[N] \mathbb{E}[X]$

Valor esperado de una VA geométrica

Ej: X VA geométrica de parámetro p (cuenta la cantidad de experimentos de Bernoulli hasta registrar el primer éxito)

► Calculamos $\mathbb{E}[X]$ condicionando por $Y = \mathbb{I}\{\text{"el primer experimento es exitoso"}\}$

⇒ Si $Y = 1$, entonces $\mathbb{E}[X | Y = 1] = 1$

⇒ Si $Y = 0$, por indep. de experimentos: $\mathbb{E}[X | Y = 0] = 1 + \mathbb{E}[X]$

► Usamos esperanzas iteradas

$$\begin{aligned}\mathbb{E}[X] &= \mathbb{E}[X | Y = 1]P(Y = 1) + \mathbb{E}[X | Y = 0]P(Y = 0) \\ &= 1 \times p + (1 + \mathbb{E}[X]) \times (1 - p)\end{aligned}$$

► Despejando $\mathbb{E}[X]$ obtenemos $\mathbb{E}[X] = \frac{1}{p}$

► En este caso el cálculo directo es sencillo (serie geométrica, derivada)

⇒ A menudo las simplificaciones son mayores

Ejemplo: el minero atrapado

- ▶ Un minero está atrapado en una mina que contiene tres puertas
- ▶ Para todo tiempo $n \geq 1$ mientras que está atrapado
 - ▶ El minero escoge una puerta $P_n = j, j = 1, 2, 3$
 - ▶ La elección de una puerta P_n es independiente de las elecciones anteriores
 - ▶ La elección de la puerta es equiprobable, i.e., $P(P_n = j) = 1/3$
- ▶ Cada puerta conduce a un túnel, pero solo un túnel va a la salida
 - ▶ Puerta 1: el minero alcanza la salida luego de dos horas de recorrido
 - ▶ Puerta 2: el minero retorna después de tres horas de recorrido
 - ▶ Puerta 3: el minero retorna después de cinco horas de recorrido
- ▶ Denotamos por X al tiempo total transcurrido hasta que el minero alcanza la salida
- ▶ Q: ¿Cuánto vale $\mathbb{E}[X]$?

Ejemplo: el minero atrapado (cont.)

- ▶ Calculamos $\mathbb{E}[X]$ condicionando a la primera puerta elegida, P_1
 - ⇒ Si $P_1 = 1$, entonces sale a las 2 horas, i.e., $\mathbb{E}[X | P_1 = 1] = 2$
 - ⇒ Si $P_1 = 2$, como elecciones son indep., $\mathbb{E}[X | P_1 = 2] = 3 + \mathbb{E}[X]$
 - ⇒ De la misma forma, si $D_1 = 3$ tenemos $\mathbb{E}[X | P_1 = 3] = 5 + \mathbb{E}[X]$
- ▶ Usamos esperanzas iteradas

$$\begin{aligned}\mathbb{E}[X] &= \sum_{j=1}^3 \mathbb{E}[X | D_1 = j] P(D_1 = j) = \frac{1}{3} \sum_{j=1}^3 \mathbb{E}[X | D_1 = j] \\ &= \frac{2 + 3 + \mathbb{E}[X] + 5 + \mathbb{E}[X]}{3} = \frac{10 + 2\mathbb{E}[X]}{3}\end{aligned}$$

- ▶ Despejando $\mathbb{E}[X]$ obtenemos

$$\mathbb{E}[X] = 10$$

- ▶ **Def:** La **varianza condicional** de X dado $Y = y$ es

$$\begin{aligned}\text{var}[X|Y = y] &= \mathbb{E}[(X - \mathbb{E}[X|Y = y])^2 | Y = y] \\ &= \mathbb{E}[X^2 | Y = y] - (\mathbb{E}[X | Y = y])^2\end{aligned}$$

⇒ $\text{var}[X|Y]$ es una función de la VA Y , su valor para $Y = y$ es $\text{var}[X|Y = y]$

- ▶ Cálculo de $\text{var}[X]$ por condicionamiento en $Y = y$. ¿Cuánto vale?
 - ⇒ $\text{var}[X] \neq \mathbb{E}_Y[\text{var}_X(X | Y)]$
 - ⇒ $\text{var}[X] \neq \text{var}_Y[\mathbb{E}_X(X | Y)]$
- ▶ **Ninguno de los dos. fórmula de varianza condicional:**

$$\text{var}[X] = \mathbb{E}_Y[\text{var}_X(X | Y)] + \text{var}_Y[\mathbb{E}_X(X | Y)]$$

Fórmula de la varianza condicional (cont.)

Demostración.

- ▶ Primer sumando: usamos linealidad y esperanzas iteradas

$$\begin{aligned}\mathbb{E}_Y[\text{var}_X(X | Y)] &= \mathbb{E}_Y [\mathbb{E}_X(X^2 | Y) - (\mathbb{E}_X(X | Y))^2] \\ &= \mathbb{E}_Y [\mathbb{E}_X(X^2 | Y)] - \mathbb{E}_Y [(\mathbb{E}_X(X | Y))^2] \\ &= \mathbb{E} [X^2] - \mathbb{E}_Y [(\mathbb{E}_X(X | Y))^2]\end{aligned}$$

- ▶ Segundo sumando: usamos def. de varianza y esperanzas iteradas

$$\begin{aligned}\text{var}_Y[\mathbb{E}_X(X | Y)] &= \mathbb{E}_Y [(\mathbb{E}_X(X | Y))^2] - (\mathbb{E}_Y[\mathbb{E}_X(X | Y)])^2 \\ &= \mathbb{E}_Y [(\mathbb{E}_X(X | Y))^2] - (\mathbb{E} [X])^2\end{aligned}$$

- ▶ Sumando ambos términos (los términos en azul se cancelan):

$$\mathbb{E}_Y[\text{var}_X(X | Y)] + \text{var}_Y[\mathbb{E}_X(X | Y)] = \mathbb{E} [X^2] - (\mathbb{E} [X])^2 = \text{var} [X]$$



Varianza de una VA compuesta

- ▶ Sean X_1, X_2, \dots VAs i.i.d. con $\mathbb{E}[X_1] = \mu$ y $\text{var}[X_1] = \sigma^2$
- ▶ Sea N una VA a valores enteros no negativos independiente de los X_i
- ▶ Consideramos la **VA compuesta** $S = \sum_{i=1}^N X_i$. ¿Cuánto vale $\text{var}[S]$?
- ▶ La fórmula de varianza condicional resulta útil aquí
- ▶ Vimos anteriormente que $\mathbb{E}[S|N] = N\mu$. ¿Qué pasa con $\text{var}[S|N = n]$?

$$\text{var} \left[\sum_{i=1}^N X_i | N = n \right] = \text{var} \left[\sum_{i=1}^n X_i | N = n \right] = \text{var} \left[\sum_{i=1}^n X_i \right] = n\sigma^2$$

⇒ $\text{var}[S|N] = N\sigma^2$. Aquí usamos la indep. de N y las VAs i.i.d. X_i

- ▶ La fórmula de varianza condicional es $\text{var}[S] = \mathbb{E}[N\sigma^2] + \text{var}[N\mu]$

Obtenemos el resultado ⇒ $\text{var} \left[\sum_{i=1}^N X_i \right] = \mathbb{E}[N]\sigma^2 + \text{var}[N]\mu^2$