

Más sobre convergencias y un poco de Estadística

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

Teorema de Slutsky

Recordamos algunas definiciones

Sean (Ω, \mathcal{E}, P) un espacio de probabilidad, y $(X_n) : \Omega \rightarrow \overline{\mathbb{R}}$ una sucesión de variables aleatorias finitas en casi todo punto. Recordamos dos nociones de convergencia (cuando $n \rightarrow +\infty$)

- Convergencia en probabilidad:

$$X_n \xrightarrow{P} X \Leftrightarrow \forall \delta > 0, \quad P\{|X_n - X| > \delta\} \rightarrow 0$$

- Convergencia en distribución:

$$X_n \xrightarrow{D} X \Leftrightarrow F_{X_n}(x) \rightarrow F_X(x)$$

para todo punto de continuidad x de F_X .

Equivalentemente, tenemos la caracterización dada por el **teorema de Helly-Bray**

$$X_n \xrightarrow{D} X \Leftrightarrow \forall \psi \in C_c^\infty(\mathbb{R}), E[\psi(X_n)] \rightarrow E[\psi(X)]$$

y también en términos de funciones características (**teorema de Levy**)

$$X_n \xrightarrow{D} X \Leftrightarrow \varphi_{X_n}(t) \rightarrow \varphi_X(t)$$

Teorema de la aplicación continua

Como vimos en la clase 18, el teorema de Helly-Bray inmediatamente implica que:

Corolario

Si $X_n \xrightarrow{D} X$ y $g : \mathbb{R} \rightarrow \mathbb{R}$ es una función continua, entonces $g(X_n) \xrightarrow{D} g(X)$.

En particular:

Corolario

Si $X_n \xrightarrow{D} X$ y $c \in \mathbb{R}$ es un constante, entonces $X_n + c \rightarrow X + c$ y $X_n \cdot c \rightarrow X \cdot c$.

Esto sale porque $g_1(x) = x + c$ y $g_2(x) = c \cdot x$ son funciones continuas.

Sin embargo, ¡hay que tener cuidado! En general **no es cierto** que si $X_n \xrightarrow{D} X$, $Y_n \xrightarrow{D} Y$, entonces $X_n + Y_n \xrightarrow{D} X + Y$.

Lema (una versión simple del teorema de Slutsky)

Sean (X_n) e (Y_n) dos sucesiones de variables aleatorias finitas con probabilidad 1. Supongamos que $X_n \xrightarrow{D} X$ e $Y_n \xrightarrow{P} 0$. Entonces $X_n + Y_n \xrightarrow{D} X$.

En el apunte de Victor Yohai pueden ver una prueba usando directamente la definición de convergencia en distribución. Yo les voy a presentar una prueba alternativa usando la caracterización dada por el teorema de Helly-Bray.

Demostración del lema (1)

Usando la caracterización dada por el teorema de Helly-Bray, queremos probar que para toda $\psi \in C_c^\infty(\mathbb{R})$,

$$E[\psi(X_n + Y_n)] \rightarrow E[\psi(X)]$$

y sabemos por hipótesis que:

$$E[\psi(X_n)] \rightarrow E[\psi(X)]$$

Luego nos bastará probar que para cada ψ fija,

$$E[\psi(X_n + Y_n)] - E[\psi(X_n)] \rightarrow 0$$

Notamos que como $\psi \in C_c(\mathbb{R})$, ψ será acotada

$$|\psi(x)| \leq C \quad \text{para todo } x, y \in \mathbb{R}$$

y cumplirá la **condición de Lipschitz**

$$|\psi(x) - \psi(y)| \leq M|x - y| \quad \text{para todo } x \in \mathbb{R}$$

donde M es cualquier cota de $|\psi'|$ (por el teorema del valor medio).

Demostración del lema (2)

Usando las observaciones anteriores, tenemos que dado $\varepsilon > 0$,

$$|\psi(X_n + Y_n) - \psi(X_n)| \leq M|Y_n| < \frac{\varepsilon}{2}$$

si

$$|Y_n| < \delta = \frac{\varepsilon}{2M}$$

Entonces, introducimos los eventos:

$$A_{n,\delta} = \{\omega \in \Omega : |Y_n(\omega)| < \delta\}$$

y podemos estimar:

$$E[|\psi(X_n + Y_n)|] - E[|\psi(X_n)| \cdot I_{A_{n,\delta}}] \leq \frac{\varepsilon}{2}$$

Demostración del lema (3)

Ahora vamos a necesitar mirar que pasa en

$$A_{n,\delta}^c = \{\omega \in \Omega : |Y_n(\omega)| \geq \delta\}$$

Ahí vamos a usar la estimación más bruta

$$|\psi(X + Y_n) - \psi(X_n)| \leq 2C$$

Entonces:

$$E[|\psi(X_n + Y_n) - \psi(X_n)| \cdot I_{A_{n,\delta}^c}] \leq 2C \cdot E[I_{A_{n,\delta}^c}] = 2C \cdot P(A_{n,\delta}^c) < \frac{\varepsilon}{2}$$

si $n \geq n_0(\varepsilon, \delta)$ pues $Y_n \xrightarrow{P} 0$. Pero $\delta = \delta(\varepsilon)$, así que en definitiva n_0 depende sólo de ε .

Demostración del lema (4)

Finalmente acotamos

$$\begin{aligned} |E[\psi(X_n + Y_n)] - E[\psi(X_n)]| &\leq E[|\psi(X_n + Y_n) - E[\psi(X_n)]|] \\ &\leq E[|\psi(X_n + Y_n) - E[\psi(X_n)|I_{A_{n,\delta}}]|] \\ &+ \leq E[|\psi(X_n + Y_n) - E[\psi(X_n)|I_{A_{n,\delta}^c}]|] \\ &\leq \frac{\varepsilon}{2} + \frac{\varepsilon}{2} = \varepsilon \end{aligned}$$

si $n \geq n_0$. O sea, que efectivamente hemos probado que:

$$E[\psi(X_n + Y_n)] - E[\psi(X_n)] \rightarrow 0$$

y como observamos antes, esto implica la validez del lema.

Lema

Sea (X_n) una sucesión de variables aleatorias finitas con probabilidad 1, tales que $X_n \xrightarrow{P} c$ donde $c \in \mathbb{R}$ es una constante. Entonces si $g : \mathbb{R} \rightarrow \mathbb{R}$ es una función boreliana continua en c , entonces:

$$Y_n = g(X_n) \xrightarrow{P} g(c)$$

Demostración del lema

Dado $\varepsilon > 0$ por definición de continuidad, existirá un $\delta > 0$ tal que $|x - c| \leq \delta$ implica $|g(x) - g(c)| \leq \varepsilon$. Luego,

$$\{|g(x) - g(c)| \geq \varepsilon\} \subset \{|x - c| \geq \delta\}$$

En particular,

$$\{|g(X_n) - g(c)| \geq \varepsilon\} \subset \{|X_n - c| \geq \delta\}$$

tomando probabilidades:

$$0 \leq P\{|g(X_n) - g(c)| \geq \varepsilon\} \leq P\{|X_n - c| \geq \delta\}$$

por lo que si el lado derecho tiende a cero cuando $n \rightarrow +\infty$, también el término del medio. O sea que si $X_n \xrightarrow{P} c$, se deduce que $g(X_n) \xrightarrow{P} g(c)$.

Teorema

Sean (X_n) e (Y_n) dos sucesiones de variables aleatorias finitas con probabilidad 1. Supongamos que $X_n \xrightarrow{D} X$ e $Y_n \xrightarrow{P} c$ donde X es otra variable aleatoria finita con probabilidad 1 y c una constante. Entonces,

- $X_n + Y_n \xrightarrow{D} X + c.$
- $X_n Y_n \xrightarrow{D} cX.$
- Si $c \neq 0,$

$$\frac{X_n}{Y_n} \xrightarrow{D} \frac{X}{c}$$

Demostración del teorema de Slutsky (1)

Para probar que $X_n + Y_n \xrightarrow{D} X + c$, escribimos:

$$X_n + Y_n = (X_n + c) + (Y_n - c)$$

Como $X_n \xrightarrow{D} X$, tendremos que $X_n + c \xrightarrow{D} X + c$ por los resultados previos.
También

$$Y_n \xrightarrow{P} c \Rightarrow Y_n - c \xrightarrow{P} 0$$

(esto sale directamente la definición).

El resultado se deduce entonces de la versión simple del teorema de Slutsky que probamos antes.

Demostración del teorema de Slutsky (2)

Similarmente, para ver que $X_n Y_c \xrightarrow{D} cX$, escribimos

$$X_n Y_n = cX_n + (Y_n - c)X_n = U_n + Z_n$$

donde llamamos $U_n = cX_n$ y $Z_n = (Y_n - c)X_n$.

Como $X_n \xrightarrow{D} X \Rightarrow U_n \xrightarrow{D} cX$ por los resultados previos.

También sabemos que $Y_n - c \xrightarrow{P} 0$. Por otra parte, (X_n) está acotada en probabilidad, ya que converge en distribución. [por el ejercicio 14, ítem d) de la práctica 8. Este resultado se deduce también de un lema que vimos en la clase 18]

Pero entonces $Z_n \xrightarrow{P} 0$ por un resultado que vimos en la clase 15, ya que es el producto de una sucesión que tiende a cero en probabilidad por una que está acotada en probabilidad, y por lo tanto $Z_n \xrightarrow{D} 0$.

Entonces usando la versión simple del teorema de Slutsky, concluimos que $X_n Y_n \xrightarrow{D} cX$.

Demostración del teorema de Slutsky (3)

Finalmente, para ver que si $c \neq 0$,

$$\frac{X_n}{Y_n} \xrightarrow{D} \frac{X}{c}$$

escribimos

$$\frac{X_n}{Y_n} = X_n \cdot \frac{1}{Y_n}$$

y observamos que

$$Y_n \xrightarrow{P} c \Rightarrow \frac{1}{Y_n} \xrightarrow{P} \frac{1}{c}$$

por el lema previo aplicado a la función $g(y) = \frac{1}{y}$ que es continua en $y = c$ si $c \neq 0$. (Este paso es esencialmente el ejercicio 17 de la práctica 8).

Entonces el resultado se deduce del ítem anterior.

Parte II

Un poco de estadística: Estimación Puntual

Sea X una variable aleatoria cuya función de distribución F desconocemos. Por ejemplo, puede tratarse del peso de una lata de arvejas. que es una variable aleatoria que varía de lata en lata. A veces se hace una hipótesis sobre la posible distribución F (por ejemplo que es normal, aunque esto no es siempre necesario).

La distribución F está caracterizada por ciertos parámetros, como por ejemplo $\mu = E[X]$ o $\sigma^2 = \text{Var}(X)$. (o si suponemos que F pertenece a una familia de distribuciones, los que definen esa familia).

Para hacerlo, se toma una **muestra aleatoria** de la población. Obtenemos de esta forma variables

$$X_1, X_2, \dots, X_n$$

que serán variables aleatorias independientes e idénticamente distribuidas con distribución F .

Dada una muestra aleatoria X_1, X_2, \dots, X_n de una distribución F y $\lambda = \lambda(F)$ un parámetro de F , un **estimador** será una una función

$$\hat{\lambda}_n(X_1, X_2, \dots, X_n)$$

(sin parámetros desconocidos) que nos permita estimar λ en algún sentido.

Por ejemplo, si μ es la esperanza de la distribución F , entonces:

$$\hat{\mu}_n = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

(conocido como **media muestral** es un estimador razonable de μ ya que por la **ley fuerte de los grandes números**

$$\bar{X}_n \xrightarrow{\text{c.s.}} \mu \quad \text{cuando } n \rightarrow +\infty$$

Se dice que \bar{X}_n es un estimador fuertemente consistente para μ .

Similarmente, ¿Cómo podríamos estimar $\sigma^2 = \text{Var}(X) = E[(X - \mu)^2]$. Un estimador que podríamos considerar razonable es

$$\hat{\sigma}_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

Este sería el valor de la variancia de la distribución empírica generada a partir de la muestra.

Vamos a ver que nuevamente, este estimador es fuertemente consistente, o sea:

$$\hat{\sigma}_n \xrightarrow{\text{c.s.}} \sigma$$

Demostración de la consistencia fuerte del estimador de la variancia

Recordando que $\text{Var}(X) = E(X^2) - E(X)^2$ también tenemos:

$$\hat{\sigma}_n^2 = \left[\frac{1}{n} \sum_{i=1}^n X_i^2 \right] - \bar{X}_n^2$$

Por la ley fuerte de los grandes números

$$\frac{1}{n} \sum_{i=1}^n X_i^2 \xrightarrow{\text{c.s.}} E(X^2)$$

Como elevar al cuadrado es una función continua

$$\hat{\sigma}_n^2 \rightarrow E[X^2] - E(X)^2 = \sigma^2$$

y por lo tante

$$\hat{\sigma}_n \xrightarrow{\text{c.s.}} \sigma$$

Estimadores (2)

Ahora bien: dado un parámetro λ pueden pensarse diferentes estimadores para λ que pueden parecer igualmente razonables.

Por ejemplo, supongamos que tenemos una población cuya distribución F sabemos que es normal $N(\mu, \sigma^2)$ con ciertos parámetros μ y σ como vimos antes. Entonces, para estimar μ podríamos usar la media muestral como vimos antes, porque μ es la esperanza de F .

Pero para la distribución normal μ también es la mediana. Por lo tanto otra forma de estimar μ podría ser usar la mediana muestral Me . Para definirla ordenamos las variables (o sea consideramos los estadísticos de orden):

$$X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$$

y definimos

$$Me = X_{((n+1)/2)} \text{ si } n \text{ es impar}$$

$$Me = \frac{1}{2} (X_{(n/2)} + X_{(n/2+1)}) \text{ si } n \text{ es par}$$

Esto lleva a preguntarnos qué propiedades es deseable que tenga un estimador, para tener un criterio para elegir un estimador sobre otro.

Sesgo de un estimador

Dado un estimador $\hat{\lambda}_n$ de un parámetro $\lambda = \lambda(F)$, se define el **sesgo** del estimador como

$$\text{sesgo}(\hat{\lambda}_n) = E[\hat{\lambda}_n] - \lambda$$

Un estimador se dice **insesgado** si

$$\text{sesgo}(\hat{\lambda}_n) = 0$$

y asintóticamente insesgado si

$$\text{sesgo}(\hat{\lambda}_n) \rightarrow 0$$

Sesgo de la media muestral

Consideramos el estimador

$$\hat{\mu}_n = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

para la esperanza $\mu = E[X]$.

Por la linealidad de la esperanza,

$$E[\bar{X}_n] = \frac{1}{n} \sum_{i=1}^n E[X_i] = \frac{1}{n} \sum_{i=1}^n \mu = \mu$$

Luego \bar{X}_n es un estimador insesgado de μ .

Sesgo para el estimador de la varianza

Ahora repitamos la cuenta con el estimador de la varianza que definimos antes. Recordamos que:

$$\hat{\sigma}_n^2 = \left[\frac{1}{n} \sum_{i=1}^n X_i^2 \right] - \bar{X}_n^2$$

Así que empezemos calculando:

$$E \left[\frac{1}{n} \sum_{i=1}^n X_i^2 \right] = \frac{1}{n} \sum_{i=1}^n E[X_i^2] = c$$

donde

$$c = E(X_i^2) = \text{Var}(X_i) + E(X_i)^2 = \sigma^2 + \mu^2$$

Sesgo para el estimador de la varianza (2)

Por otra parte, necesitamos calcular $E[\bar{X}_n^2]$. Para ello, la observación clave es que como las variables X_i son **independientes**

$$\text{Var}(\bar{X}_n^2) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = \frac{\sigma^2}{n}$$

Entonces:

$$E(\bar{X}_n^2) = \text{Var}(\bar{X}_n^2) + E[\bar{X}_n]^2 = \frac{\sigma^2}{n} + \mu^2$$

Entonces:

$$E[\hat{\sigma}_n^2] = \sigma^2 + \mu^2 - \left(\frac{\sigma^2}{n} + \mu^2 \right) = \sigma^2 \left(1 - \frac{1}{n} \right) = \sigma^2 \left(\frac{n-1}{n} \right)$$

Luego este estimador no resulta insesgado, pero sí asintóticamente insesgado.

Estimador incesgado de la varianza

Si queremos tener un estimador incesgado de la varianza, debemos reemplazarlo por:

$$S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

que aparece en el ejercicio 24 de la pratica 8, ya que como

$$S_n^2 = \frac{n}{n-1} \cdot \hat{\sigma}_n^2$$

ahora tendremos que:

$$E[S_n^2] = \sigma^2$$

(si se fijan, hemos resuelto todo el ejercicio).

Parte III

Intervalos de confianza

Planteo del problema

Hasta ahora vimos como estimar los parámetros de una distribución. Por ejemplo si sabemos (o conjeturamos) que tenemos una muestra de la distribución normal $N(\mu, \sigma^2)$ podemos estimar los parámetros.

¿Pero cómo podemos estimar el error cometido en la estimación? Primero consideraremos el caso más sencillo aunque poco realista en que σ es conocido y queremos estimar μ . Sabemos que podemos estimar μ usando la medida muestral $\hat{\mu}_n = \bar{X}_n$.

Nos gustaría encontrar un **intervalo de confianza** para μ , es decir un intervalo alrededor de $\hat{\mu}_n$ tal que

$$P\{\mu \in I_\alpha\} = 1 - \alpha$$

donde $0 < \alpha < 1$ es un **nivel de confianza** elegido (típicamente $\alpha = 0,05$).

Ya nos encontramos con este concepto en un ejemplo que vimos en la clase 7 sobre las aproximaciones de la normal (encuesta electoral).

Solución cuando la varianza es conocida

Cuando la distribución es normal y σ es conocida podemos razonar así: \bar{X}_n tendrá distribución $N\left(\mu, \frac{\sigma^2}{n}\right)$ Entonces:

$$Z_n = \sqrt{n} \cdot \frac{\bar{X}_n - \mu}{\sigma} \sim N(0, 1)$$

Ahora elegimos $z_{\alpha/2}$ de modo que $P(Z_n > z_{\alpha/2}) = \alpha/2$, y por la simetría de la curva normal tenemos que

$$P\{-z_{\alpha/2} \leq -Z_n \leq z_{\alpha/2}\} = 1 - \alpha$$

Dejando obtenemos el intervalo de confianza

$$I_\alpha = \left[\bar{X}_n - \frac{z_{\alpha/2}\sigma}{\sqrt{n}}, \bar{X}_n + \frac{z_{\alpha/2}\sigma}{\sqrt{n}} \right]$$

para el que podemos garantizar que

$$P\{\mu \in I_\alpha\} = 1 - \alpha$$

Intervalos de confianza asintóticos

En la realidad, no es realista suponer que la distribución es conocida, o que la varianza lo es. De todos modos, podemos definir un intervalo de confianza asintótico para $\mu = E[X]$, reemplazando a σ por un estimador fuertemente consistente $\hat{\sigma}_n$ de los que vimos antes (da igual cuál consideremos)

$$I_\alpha = \left[\bar{X}_n - \frac{z_{\alpha/2} \hat{\sigma}_n}{\sqrt{n}}, \bar{X}_n + \frac{z_{\alpha/2} \hat{\sigma}_n}{\sqrt{n}} \right]$$

Con sólo suponer que la variancia de la distribución tendremos que:

$$Z_n = \sqrt{n} \cdot \frac{\bar{X}_n - \mu}{\sigma} \xrightarrow{D} N(0, 1)$$

por el teorema del límite central, siempre que $\sigma^2 = \text{Var}(X_i) < \infty$.

Intervalos de confianza asintóticos (2)

Como

$$\frac{\sigma}{\hat{\sigma}_n} \xrightarrow{c.s.} 1$$

tendremos que la convergencia en distribución no se ve alterada:

$$\hat{Z}_n = \frac{\sigma}{\hat{\sigma}_n} Z_n = \sqrt{n} \cdot \frac{\bar{X}_n - \mu}{\hat{\sigma}_n} \xrightarrow{D} N(0, 1)$$

por el teorema de Slutsky.

Por lo que nuestro intervalo

$$I_\alpha = \left[\bar{X}_n - \frac{z_{\alpha/2} \hat{\sigma}_n}{\sqrt{n}}, \bar{X}_n + \frac{z_{\alpha/2} \hat{\sigma}_n}{\sqrt{n}} \right]$$

verfica que

$$\lim_{n \rightarrow +\infty} P\{\mu \in I_\alpha\} = 1 - \alpha$$