

Clase 24/05/2023.

(1)

Convergencia de variables aleatorias
La semana pasada introdujimos la noción de convergencia
en probabilidad: Decimos que una sucesión $\{X_m\}_{m=1}^{\infty}$
de variables aleatorias converge en probabilidad
a la v.a. X si se tiene que

$$\lim_{m \rightarrow \infty} \mathbb{P}(|X_m - X| > \varepsilon) = 0.$$

En lenguaje ~~coloquial~~ coloquial la convergencia
en probabilidad nos dice que $X_m(\omega)$ se aproxima
a X en un conjunto de probabilidad grande o
lo que es lo mismo que X_m está separado de X
a lo sumo por $\varepsilon > 0$ en un conjunto de probabilidad
pequeña.

Convergencia en media cuadrática (o en L^2)

Una sucesión de v.a. $\{X_m\}_{m=1}^{\infty}$ converge en
media cuadrática si

$$E|X_m - X|^2 \xrightarrow{m \rightarrow \infty} 0.$$

La desigualdad de Chebyshev nos permite
demostrar la siguiente implicación

Convergencia en media cuadrática \Rightarrow converg en Prob

Otra sección importante es la convergencia casi segura (2)
segura c.s.

Convergencia casi segura

$X_n \rightarrow X$ c.s. si existe un subconjunto N tal que $P(N) = 0$ de ω y si $\omega \notin N$ entonces $X_n(\omega) \rightarrow X(\omega)$

Inaunque no lo demostraré se tiene que

$$X_n \xrightarrow{cs} X \implies X_n \rightarrow X \text{ en probabilidad}$$

Finalmente está la noción de convergencia en distribución

$X_n \xrightarrow{d} X$ (en distribución) si $F_n(x)$ y $F(x)$ denotan respectivamente las distribuciones de X_n y de X ; esto es $F_n(x) = P(X_n \leq x)$ y

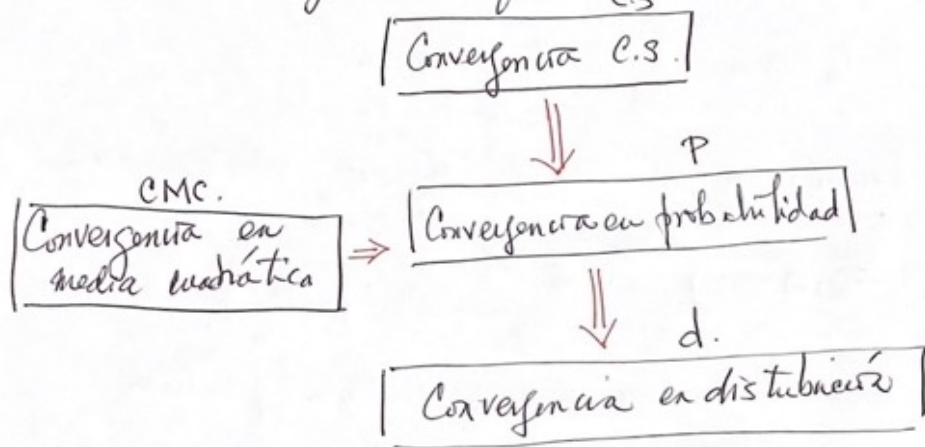
$$F(x) = P(X \leq x). \text{ Entonces}$$

$X_n \xrightarrow{d} X$ si $\forall x$ de continuidad de $F(x)$ se verifica $F_n(x) \rightarrow F(x)$

Convergencia en probabilidad \implies Convergencia en distribución

Tenemos el siguiente esquema

(3)



Veamos que si $X_n \xrightarrow{MC} X \Rightarrow X_n \xrightarrow{P} X$, es efecto.

$$P(|X_n - X| > \epsilon) \leq \frac{1}{\epsilon^2} E(|X_n - X|^2) \rightarrow 0.$$
 pues el lado derecho tiende a Cero por la convergencia en MC.

Las otras implicaciones son más laboriosas de demostrar

Ahora veamos un ejemplo muy sencillo sea $\{Y_m\}_{m=1}^{\infty}$ una colección de v.a. $N(0, \sigma_m^2)$ entonces si $\sigma_m^2 \rightarrow \sigma^2$

$$Y_m \xrightarrow{d} Z = N(0, \sigma^2).$$

En efecto

$$F_n(x) = \int_{-\infty}^x \frac{e^{-\frac{u^2}{2\sigma^2}}}{\sqrt{2\pi}\sigma} du$$

hacemos en la integral $\frac{u}{\sigma} = v$ obtenemos en

$$F_n(x) = \int_{-\infty}^{\frac{x}{\sigma}} \frac{e^{-v^2/2}}{\sqrt{2\pi}} v = \Phi\left(\frac{x}{\sigma}\right);$$

pero Φ es una función continua y entonces

$$\Phi\left(\frac{x}{\sigma_n}\right) \rightarrow \Phi\left(\frac{x}{\sigma}\right)$$

luego

$$F_n(x) \rightarrow Z = N(0, \sigma^2)$$

Nuevo tema: Estimación

Consideremos el siguiente problema tenemos que ~~un~~ modelo para modelar un fenómeno donde interviene el azar tenemos a disposición una densidad (o más bien una familia de densidades) que dependen de uno o varios parámetros. Por ejemplo nuestro modelo es la gaussiana $N(\mu, \sigma^2)$ y suponemos que disponemos

de un conjunto de observaciones. Tomadas de una población de manera independiente (5)

$$X_1(\omega), X_2(\omega), \dots, X_n(\omega) \dots$$

Supongamos que dichas observaciones provienen de un mismo modelo. Entonces nos preguntamos ¿A partir de estas observaciones como inferir el valor de los parámetros?

Tomemos como ejemplo la $N(\mu, 1)$ una familia con densidad

$$\frac{e^{-\frac{(x-\mu)^2}{2}}}{\sqrt{2\pi}}$$

Podemos entonces definir a partir de las observaciones la media empírica

$$\bar{X} = \frac{X_1(\omega) + X_2(\omega) + \dots + X_n(\omega)}{n}$$

Sabemos también que si $Z \sim N(\mu, 1)$

$$E(Z) = \mu$$

Entonces por la LGN tenemos:

$$\bar{X}_n \xrightarrow{P} E(X_i) = \mu \text{ luego sabemos que}$$

(6)

Construimos a partir de X_1, \dots, X_n la media empírica y sabemos que nos aproximamos en probabilidad al verdadero valor del parámetro.

Otro ejemplo es el de la varianza de una gaussiana $N(2, \sigma^2)$ (conocemos de la esperanza que es igual a 2).

Podemos entonces definir

$$\hat{m}_2 = \frac{X_1^2 + X_2^2 + \dots + X_n^2}{n}$$

momento empírico de segundo orden si

$Z \sim N(2, \sigma^2)$ su densidad es

$$\frac{e^{-\frac{(x-2)^2}{2\sigma^2}}}{\sqrt{2\pi} \sigma}$$

Al calcular el segundo momento

$$m_2 = \int_{-\infty}^{\infty} x^2 \frac{e^{-\frac{(x-2)^2}{2\sigma^2}}}{\sqrt{2\pi} \sigma} dx = \int_{-\infty}^{\infty} (\sigma v + 2)^2 \frac{e^{-\frac{v^2}{2}}}{\sqrt{2\pi}} dv$$

$m_2 = \sigma^2 + 4$ y entonces tenemos

(7)

$$\widehat{m}_{2,n} = \frac{X_1^2 + \dots + X_n^2}{n}$$

$$E \widehat{m}_{2,n} = \frac{n\sigma^2 + n4}{n} = \sigma^2 + 4$$

Luego
$$\widehat{m}_{2,n} - 4 = \frac{(X_1^2 - 4) + (X_2^2 - 4) + \dots + (X_n^2 - 4)}{n}$$

$$E \widehat{m}_{2,n} - 4 = \sigma^2$$

pero además la LGN implica que

$$\widehat{m}_{2,n} - 4 \rightarrow \sigma^2$$

Estadístico y estimador

Un estadístico T es una variable aleatoria que se calcula en función de las variables X_1, \dots, X_n y en general lo escribimos

$$T(X_1, X_2, \dots, X_n)$$

Un estimador es un estadístico, que creemos que contiene relevante o de la distribución común de la $\{X_i\}$ que denotamos por X .

Método de estimación

(8)

① Método de los momentos

Para ilustrarlo trabajemos el siguiente ejemplo.

Sea X_1, X_2, \dots, X_n una muestra aleatoria simple (o muestra aleatoria que proviene de una densidad

$$f(x; \theta) = (\theta+1)x^\theta \quad \text{para } x \in [0, 1]$$

Calculemos la esperanza

$$E(X) = (\theta+1) \int_0^1 x^{\theta+1} dx = \frac{(\theta+1)}{(\theta+2)}$$

Esto quiere decir que la esperanza de X es una función del parámetro $g(\theta)$ en nuestro

caso $g(\theta) = \frac{(\theta+1)}{(\theta+2)}$

Si calculamos la media muestral \bar{X}_n el estimador de momentos consiste en igualar a la media empírica a $g(\theta)$ y despejar. Esto es

entonces $\bar{X}_n = \frac{\theta+1}{\theta+2}$ y el estimador será

$$\hat{\theta} = \bar{g}^{-1}(\bar{X}_n) \quad \text{que en este caso podemos calcular sin problemas.}$$

(9)

$$\bar{X}_n(\hat{\theta}+2) = \hat{\theta}+1$$

$$\bar{X}_n \hat{\theta} - \hat{\theta} = 1 - 2\bar{X}_n$$

$$\text{luego } \hat{\theta}(\bar{X}_n - 1) = 1 - 2\bar{X}_n$$

$$\Rightarrow \boxed{\hat{\theta} = \frac{1 - 2\bar{X}_n}{\bar{X}_n - 1}}$$

El método funciona igual cuando hay más parámetros

$$\bar{m}_1 = \bar{X}_n$$

$$\bar{m}_2 = \frac{X_1^2 + \dots + X_n^2}{n}$$

Si $X \sim N(\mu, \sigma^2)$ tenemos

$$\bar{X}_n = \hat{\mu}$$

$$\bar{m}_2 = \frac{X_1^2 + \dots + X_n^2}{n} = \sigma^2 + \mu^2$$

$$\Rightarrow \hat{\sigma}^2 = \bar{m}_2 - \hat{\mu}^2 = \bar{m}_2 - \left(\frac{1}{n} \sum_{i=1}^n X_i\right)^2$$

$$\boxed{\hat{\sigma}^2 = \bar{m}_2 - \bar{m}_1^2}$$

Notión de consistencia:

(18)

Diremos que un estimador es consistente en probabilidad si

$$T_n(X_1, \dots, X_n) \xrightarrow{P} \theta \quad (\text{Verdadero valor de parámetro})$$

y será consistente en norma cuadrática si

$$E(T_n - \theta)^2 \xrightarrow{m \rightarrow \infty} 0.$$

Todo estimador consistente en norma cuadrática lo es en probabilidad, pero el recíproco no siempre es cierto.

Ejemplo:

$$\boxed{\bar{X}_n \xrightarrow{P} E(X) = \mu}$$

$$\bar{m}_2 = \frac{X_1^2 + \dots + X_n^2}{n} \xrightarrow{P} E(X^2) \stackrel{\text{caso gaussiano}}{=} \sigma^2 + \mu^2$$

luego como se tiene que si $X_n \xrightarrow{P} X$ e $Y_n \xrightarrow{P} Y$

$$\boxed{X_n + Y_n \xrightarrow{P} X + Y}$$

y si f es una función continua y $X_n \xrightarrow{P} X$

$$\Rightarrow \boxed{f(X_n) \xrightarrow{P} f(X)}$$

(11)

Entonces:

En el caso Gaussiano

$$\begin{cases} \bar{m}_2 \xrightarrow{P} \sigma^2 + \mu^2 \\ (\bar{m}_1)^2 \xrightarrow{P} \mu^2 \end{cases}$$

Entonces usando el teorema

$$\boxed{\bar{m}_2 - (\bar{m}_1)^2 \rightarrow \sigma^2}$$

Veamos una igualdad interesante. Definamos el estadístico

$$\frac{1}{n} \sum_{j=1}^n (X_j - \bar{X}_n)^2 = \frac{1}{n} \left[\sum_{j=1}^n X_j^2 - 2\bar{X}_n \sum_{j=1}^n X_j + n(\bar{X}_n)^2 \right]$$

$$= \frac{1}{n} \left[\sum_{j=1}^n X_j^2 - 2n(\bar{X}_n)^2 + n(\bar{X}_n)^2 \right]$$

$$= \frac{1}{n} \sum_{j=1}^n X_j^2 - \bar{X}_n^2 = \underline{\bar{m}_2 - (\bar{m}_1)^2}$$