

Groucho Marx

“

JAMÁS ACEPTARÍA
PERTENECER A
UN CLUB QUE
ADMITIERA COMO
MIEMBRO A ALGUIEN
COMO YO.

“frases

Probabilidad - Clase 30

Teorema Central del Límite (TCL)

Ernesto Mordecki

Facultad de Ciencias, Universidad de la República. Montevideo, Uruguay

Curso de la Licenciatura en Matemática - 2020

Contenidos

Ley de los grandes números (Chebishev)

Sucesión de v.a.i.i.d.

Teorema Central del Límite

Aplicación: Teorema de De-Moivre - Laplace

Aplicación para simulación

Teorema (Chebishev)

Consideremos una sucesión de variables aleatorias

$$X_1, X_2, \dots,$$

independientes dos a dos, y con esperanzas matemáticas a_1, a_2, \dots . Supongamos que se cumple la condición

$$\mathbf{var} X_n \leq C, \quad n = 1, 2, \dots,$$

donde C es una constante arbitraria. Entonces

$$\frac{1}{n} \sum_{i=1}^n X_i - \frac{1}{n} \sum_{i=1}^n a_i \xrightarrow{\mathbf{P}} 0. \quad (1)$$

Corolario: teorema de Bernoulli

- ▶ Consideremos n experimentos independientes, con 2 resultados (éxito y fracaso), y probabilidad de éxito igual a p en cada experimento ($0 < p < 1$).
- ▶ Sea μ la cantidad de éxitos en n experimentos.
- ▶ Sea X_1, X_2, \dots una sucesión de variables aleatorias, cada una de las cuales toma el valor 1 con probabilidad p (si ocurre un éxito) y el valor 0 con probabilidad $q = 1 - p$ (si ocurre un fracaso).

- ▶ Tenemos $\mathbf{E} X_i = p$, $\mathbf{var} X_i = pq \leq 1$ para cada $i = 1, 2, \dots$.
- ▶ Además $\mu = \sum_{i=1}^n X_i$, porque la suma contiene tantos sumandos iguales a uno como éxitos ocurren en los primeros n experimentos, siendo nulos los sumandos restantes.
- ▶ Las variables aleatorias X_1, X_2, \dots son independientes dos a dos y cumplen la condición $\mathbf{var} X_i \leq 1$ ($i = 1, 2, \dots$), por lo que es aplicable el teorema de Chebishev:

$$\mu/n \xrightarrow{\mathbf{P}} p.$$

- ▶ La última afirmación significa que la frecuencia de éxitos en n experimentos, converge en probabilidad a p , la probabilidad de éxito en un experimento.

Sucesión de v.a.i.i.d.

- ▶ Un concepto central en probabilidad y estadística es la de *sucesión de variables aleatorias independientes e idénticamente distribuidas*¹
- ▶ Se trata de una sucesión X_1, X_2, \dots de v.a. tales que
 - ▶ Para todo n las v.a. X_1, \dots, X_n son independientes
 - ▶ La distribución de todas las variables es igual (a la de X_1 , por ejemplo).
- ▶ En particular, las variables son independientes dos a dos (como en el T. de Chebishev).

¹eso suena tan raro porque imita al inglés: *sequence of independent and identically distributed random variables (i.i.d. r.v.)*

Teorema Central del Límite²

Consideremos una sucesión de v.a.i.i.d.

$$X_1, X_2, \dots$$

Supongamos que tienen

- ▶ Esperanza finita: $\mathbf{E} X_1 = a$.
- ▶ Varianza finita y positiva: $\mathbf{var} X_1 = \sigma^2 > 0$

Entonces

$$\mathbf{P} \left(a < \frac{X_1 + X_2 + \dots + X_n - na}{\sigma\sqrt{n}} \leq b \right) \rightarrow \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{1}{2}t^2} dt.$$

cuando $n \rightarrow \infty$, uniformemente en a, b .

²Teorema de Lindeberg-Lévy

El TCL es un resultado de velocidad de convergencia:

- ▶ Nosotros sabemos que

$$\frac{X_1 + X_2 + \cdots + X_n}{n} \rightarrow a.$$

- ▶ es decir

$$\frac{X_1 + X_2 + \cdots + X_n}{n} - a \rightarrow 0.$$

¿A que velocidad tiende a cero?

- ▶ Determinar α tal que

$$\frac{X_1 + X_2 + \cdots + X_n}{n} - a \sim \frac{1}{n^\alpha}.$$

- ▶ es decir

$$n^\alpha \left(\frac{X_1 + X_2 + \cdots + X_n}{n} - a \right) \sim 1.$$

- ▶ Resulta que $\alpha = 1/2$

$$\sqrt{n} \left(\frac{X_1 + X_2 + \cdots + X_n}{n} - a \right) \sim \text{algo.}$$

- ▶ cuentas...

$$\frac{X_1 + X_2 + \cdots + X_n - na}{\sqrt{n}} \sim \text{algo.}$$

- ▶ y ese algo resulta σZ (no es constante, pero no depende de n !)

- ▶ cuentas...

$$\frac{X_1 + X_2 + \cdots + X_n - na}{\sigma\sqrt{n}} \sim Z.$$

- ▶ Por último, teníamos

$$\frac{X_1 + X_2 + \cdots + X_n - na}{\sigma\sqrt{n}} \sim Z.$$

- ▶ podemos escribir

$$X_1 + X_2 + \cdots + X_n - na \sim \sigma\sqrt{n}Z.$$

- ▶ Resulta:

$$X_1 + X_2 + \cdots + X_n \sim na + \sigma\sqrt{n}Z.$$

Una idea

Sea

$$S_n = X_1 + X_2 + \cdots + X_n, \quad Z_n = \frac{S_n - na}{\sigma\sqrt{n}}$$

Tenemos

$$\mathbf{E} Z_n = \frac{\mathbf{E} S_n - na}{\sigma\sqrt{n}} = \frac{n\mathbf{E} X_1 - na}{\sigma\sqrt{n}} = 0.$$

$$\mathbf{var} Z_n = \mathbf{var} \left(\frac{S_n - na}{\sigma\sqrt{n}} \right) = \frac{\mathbf{var} S_n}{\sigma^2 n} = \frac{n\mathbf{var} X_1}{n\sigma^2} = 1^3.$$

Sea $Z \sim \mathcal{N}(0, 1)$. Lo que dice el TCL es

$$\mathbf{P}(a < Z_n \leq b) \rightarrow \mathbf{P}(a < Z \leq b).$$

³Se usa la independencia

³Se usa la independencia

Normalización de variables

Si consideramos las variables *normalizadas*

$$Y_n = \frac{X_n - a}{\sigma},$$

tenemos

$$\mathbf{E} Y_n = \frac{1}{\sigma} \mathbf{E} (X_n - a) = \frac{1}{\sigma} (\mathbf{E} X_n - a) = 0.$$

$$\mathbf{var} Y_n = \frac{1}{\sigma^2} \mathbf{var} (X_n - a) = \frac{1}{\sigma^2} \mathbf{var} X_n = 1.$$

Ademas, son i.i.d. El teorema para las $\{Y_n\}$ queda así:

$$\mathbf{P} \left(a < \frac{Y_1 + Y_2 + \cdots + Y_n}{\sqrt{n}} \leq b \right) \rightarrow \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{1}{2}t^2} dt.$$

Aplicación: Teorema de De-Moivre - Laplace

Supongamos como antes que tenemos un esquema de Bernoulli:

$$X_n = \begin{cases} 1, & \text{con probabilidad } p \\ 0, & \text{con probabilidad } 1 - p = q. \end{cases}$$

Entonces

$$\mathbf{E} X_1 = p, \quad \mathbf{var} X_1 = pq$$

Si llamamos $\mu_n = X_1 + \dots + X_n$, el TCL nos dice

$$\mathbf{P} \left(a < \frac{\mu_n - np}{\sqrt{npq}} \leq b \right) \rightarrow \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{1}{2}t^2} dt.$$

que es exactamente el enunciado del TCL de De-Moivre - Laplace.

Aplicación para simulación

Una forma aproximada de simular variables normales, es a través del TCL. Como las variables básicas que se simulan son uniformes, es claro que si n es suficientemente grande se puede utilizar el TCL para simular v.a. normales. Sea entonces U_1, U_2, \dots v.a.i. uniformes en $[0, 1]$. Tenemos

$$\mathbf{E} U_1 = \int_0^1 x dx = \left[\frac{x^2}{2} \right]_0^1 = \frac{1}{2}.$$

$$\begin{aligned} \mathbf{var} U_1 &= \mathbf{E}(U_1^2) - (\mathbf{E} U_1)^2 = \int_0^1 x^2 dx - \left(\frac{1}{2} \right)^2 \\ &= \left[\frac{x^3}{3} \right]_0^1 - \frac{1}{4} = \frac{1}{3} - \frac{1}{4} = \frac{1}{12}. \end{aligned}$$

¿Cuántas variables se precisan?

- ▶ En realidad, precisamos un teorema de *velocidad* de aproximación
- ▶ En la práctica se usa $n = 6$ (para variables uniformes)
- ▶ Como

$$\frac{1}{2}n = 3, \quad n\sigma^2 = \frac{6}{12} = \frac{1}{2}.$$

Resulta

$$Z_n = \sqrt{2}(U_1 + \cdots + U_6 - 3) \sim Z.$$

- ▶ Geometricamente, la probabilidad puede verse como el volumen de un tetraedro inserto en un hiper-cubo

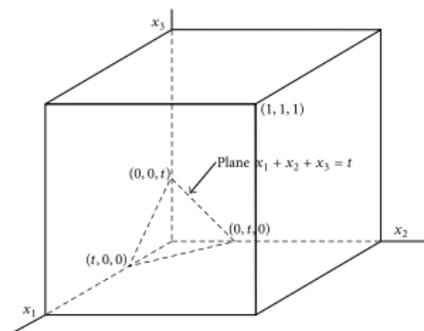


Figura: Suma de 3 variables uniformes (distribución de Irwin-Hall)

Irwin-Hall distribution

Probability density function

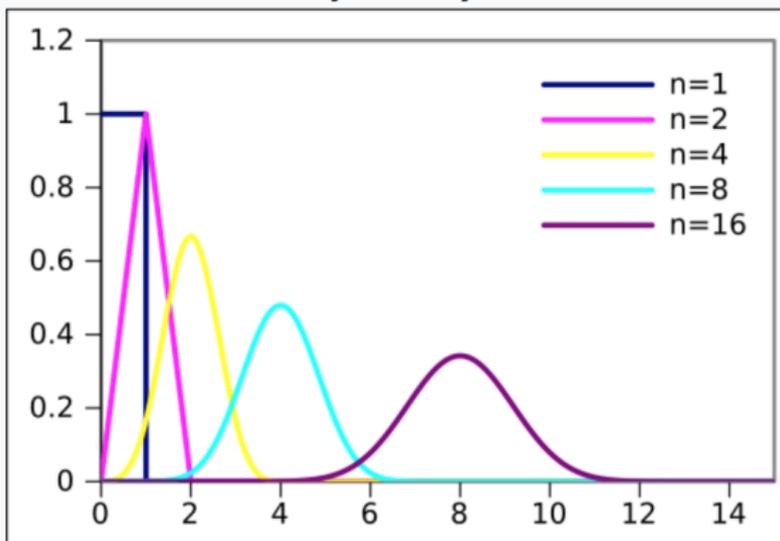


Figura: Suma de n variables uniformes (distribución de Irwin-Hall)

La campana de Gauss extendida:

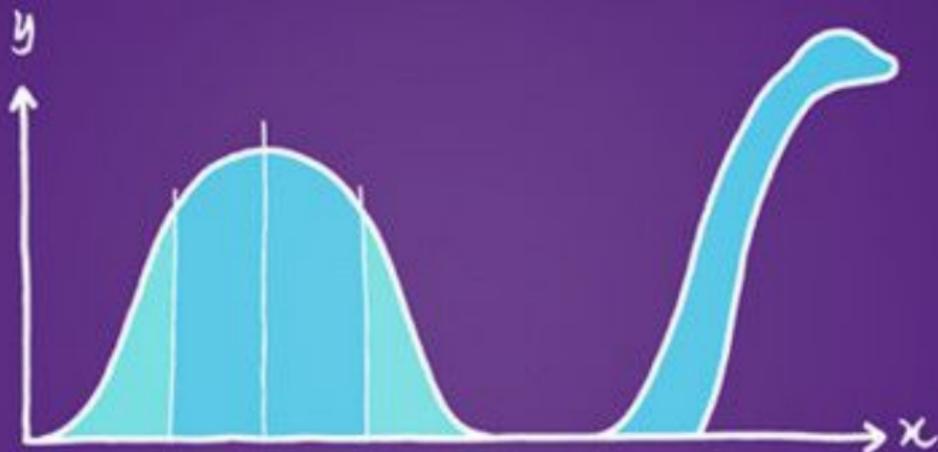


fig 1.0 The Extended Bell Curve.