

7: Conceptos y aplicaciones de convergencia de variables aleatorias

En la parte de inferencia estadística nos interesa describir algún fenómeno aleatorio.

① Primero asumir

$$\text{fenómeno aleatorio} \equiv X \rightsquigarrow f_X(x|\theta)$$

no conocer θ , el parámetro que gobierna la forma del comportamiento agregado ideal que estamos suponiendo para el fenómeno aleatorio.

② En qué el interés se centra en

$$\mu = \mathbb{E}(X) \quad \text{"el comportamiento medio"}$$

③ Para estimar μ necesitamos datos, x_1, x_2, \dots, x_n

\Rightarrow Asumir que esos datos son solo una realización de

X_1, X_2, \dots, X_n v.a. independientes en cada

$$X_i \rightsquigarrow f_X(x|\theta), \quad i=1, 2, 3, \dots, n.$$

$$\equiv \underline{\text{m.a.}} \equiv \underline{\text{v.o.i.i.d}}$$

④ Tentar de estimar μ con

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

¿Por qué?

$$\mathbb{E}(\bar{X}_n) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i) \\ = \mu$$

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

$$\Rightarrow \lim_{n \rightarrow \infty} \text{Var}(\bar{X}_n) = 0$$

\Rightarrow Si n es muy grande

$\Rightarrow \bar{X}_n \xrightarrow[n \rightarrow \infty]{} \mu$
converge en algún sentido

Queremos que formalizar estas ideas

El que \bar{X}_n converge a μ (en algún sentido) nos da confianza para usar a \bar{X}_n para estimar a μ . Pero y si buscamos una medida en términos de "probabilidades" para saber que

tan buena o mala es nuestra estimación

\Rightarrow necesitamos

$$\bar{X}_n \rightsquigarrow \hat{\theta}?$$

y es fácil ver que si

$$Z_n = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}$$

$$\mathbb{E}(Z_n) = 0 \quad \text{y} \quad \text{Var}(Z_n) = 1$$

\Rightarrow tanto la media y varianza permanecen constantes a medida que n aumenta.

Esto nos da la oportunidad de estudiar la distribución cuando $n \rightarrow \infty$, en otros palabras

$$\lim_{n \rightarrow \infty} F_{Z_n}(z) = F_Z(z) \quad \leftarrow \hat{\theta}?$$

El Teorema Central de Límite indica que bajo supuestos mínimos de hecho $Z_n \rightsquigarrow N(0,1)$

End primer caso bajo supuestos mínimos

$$\bar{X}_n \xrightarrow{P} \mu$$

End segundo caso

$$Z_n \xrightarrow{D} Z$$

Para formalizar estos conceptos necesitamos dar desigualdades

Desigualdad de Markov

Si la v.a. X sólo toma valores positivos

$$\Rightarrow P(X \geq \varepsilon) \leq \frac{E(X)}{\varepsilon}, \quad \forall \varepsilon > 0$$

Dem.

$$\begin{aligned} E(X) &= \int_0^{\infty} x f(x) dx \\ &= \int_0^{\varepsilon} x f(x) dx + \int_{\varepsilon}^{\infty} x f(x) dx \\ &\geq \int_{\varepsilon}^{\infty} x f(x) dx \end{aligned}$$

$$\geq \int_{\epsilon}^{\infty} \epsilon f(x) dx = \epsilon P(X \geq \epsilon)$$

$$\Rightarrow P(X \geq \epsilon) \leq \mathbb{E}(X)/\epsilon \quad \square$$

Desigualdad de Chebyshev

Sea X una v.a. con $\mu = \mathbb{E}(X)$ y $G^2 = \text{Var}(X)$

$$\Rightarrow P(|X - \mu| \geq \epsilon) \leq \frac{G^2}{\epsilon^2}, \quad \forall \epsilon > 0$$

Dem

$$P(|X - \mu| \geq \epsilon) = P((X - \mu)^2 \geq \epsilon^2)$$

$$\leq \frac{\mathbb{E}((X - \mu)^2)}{\epsilon^2}$$

$$= \frac{G^2}{\epsilon^2} \quad \square$$

Ley débil de los grandes números (LDGN)

Sea X_1, X_2, \dots, X_n un m.a. d X y $\mu = \mathbb{E}(X)$.
con $G^2 = \text{Var}(X) < \infty$

Para cualquier $\epsilon > 0$, se tiene que

$$\lim_{n \rightarrow \infty} P(|\bar{X}_n - \mu| \geq \epsilon) = 0$$

en otras palabras por n suficientemente grande \bar{X}_n está
concentrada en μ , i.e. $[\mu - \epsilon, \mu + \epsilon]$

Dem

$$\begin{aligned} P(|\bar{X}_n - \mu| \geq \epsilon) &= P((\bar{X}_n - \mu)^2 \geq \epsilon^2) \\ &\leq \frac{\mathbb{E}((\bar{X}_n - \mu)^2)}{\epsilon^2} \\ &= \frac{\text{Var}(\bar{X}_n)}{\epsilon^2} \\ &= \frac{G^2}{n\epsilon^2} \end{aligned}$$

$$\lim_{n \rightarrow \infty} P(|\bar{X}_n - \mu| \geq \epsilon) = 0$$

□

Ejemplo

Sea p la proporción de votantes que apoyan a un determinado candidato a un puesto de elección popular.

Si pudieramos seleccionar una m.c. de votantes

$$X_1, X_2, \dots, X_n, \quad X_i \sim \text{Bernoulli}(p)$$

¿qué tan grande debe ser n para que

$$P(|\bar{X}_n - \mu| \leq 0.01) \geq 0.95 \quad ?$$

$$\Leftrightarrow \underline{\underline{P(|\bar{X}_n - \mu| \geq 0.01) \leq 0.05}}$$

$$P(|\bar{X}_n - \mu| \geq 0.01) \leq \frac{\text{Var}(\bar{X}_n)}{(0.01)^2} = \frac{p(1-p)}{n(0.01)^2} \leq \frac{1}{4n(0.01)^2}$$

$$\frac{1}{4n(0.01)^2} = 0.05$$

$$n = \frac{1}{4(0.01)^2(0.05)}$$

Convergencia en probabilidad

La convergencia que conocemos de cálculo está dada por

Sea y_1, y_2, \dots una sucesión de números reales y sea a otro número real. Decimos que

$$\lim_{n \rightarrow \infty} y_n = a$$

Si $\forall \epsilon > 0$, existe $n_0 \in \mathbb{N}$.

$$|y_n - a| < \epsilon \quad \text{para todo } n \geq n_0$$

Convergencia en probabilidad

Sea $\mathbb{Y}_1, \mathbb{Y}_2, \dots$ una sucesión de v.c. (no necesariamente independientes) y a un número real. Decimos que \mathbb{Y}_n converge en probabilidad a \underline{a} , i.e.

$$\mathbb{Y}_n \xrightarrow{P} a$$

Si $\forall \epsilon > 0$, se tiene que

$$\lim_{n \rightarrow \infty} P(|\mathbb{Y}_n - a| \geq \epsilon) = 0$$

Dada esta definición, podemos ver su L.D.G.N simplemente
es convergencia en probabilidad

$$\bar{X}_n \xrightarrow{P} \mu$$

Ejemplo

Sea X_1, \dots, X_n un m.a. de $U(0,1)$ y definir

$$Y_n = \min\{X_1, \dots, X_n\} = X_{(1)}$$

intuitivamente Y_n se aproxima a cero a medida que n
crece. Pero

$$\text{¿} Y_n \xrightarrow{P} 0 \text{?}$$

$$\begin{aligned} P(|Y_n - 0| \geq \epsilon) &= P(Y_n \geq \epsilon) \\ &= P(X_1 \geq \epsilon, X_2 \geq \epsilon, \dots, X_n \geq \epsilon) \\ &= \prod_{i=1}^n P(X_i \geq \epsilon) \\ &= P(X \geq \epsilon)^n \\ &= (1 - P(X \leq \epsilon))^n \\ &= (1 - \epsilon)^n \end{aligned}$$

$$\text{Como } \lim_{n \rightarrow \infty} (1 - \epsilon)^n = 0 \quad \Rightarrow \quad \underline{Y_n \xrightarrow{P} 0}$$