

Introducción

Consideremos una situación experimental donde la variable de interés X , tiene función de densidad o de probabilidad $f(x)$

Definición 1 Un conjunto X_1, X_2, \dots, X_n de variables aleatorias que son mutuamente independientes y que tienen la misma función de densidad o de probabilidad $f(x)$ se llama muestra aleatoria de tamaño n de la población $f(x)$

Muchos veces decimos que X_1, X_2, \dots, X_n son variables aleatorias independientes idénticamente distribuidas, y lo abreviaremos como i.i.d.

A partir de lo anterior la función de probabilidad o densidad conjunta de X_1, \dots, X_n está dada

$$f(x_1, \dots, x_n) = \prod_{i=1}^n f(x_i)$$

$$f(x_1, \dots, x_n) = \prod_{i=1}^n f(x_i)$$

Si se tiene una familia paramétrica de densidades o funciones de probabilidad obtenemos

$$f(x_1, \dots, x_n | \theta) = \prod_{i=1}^n f(x_i | \theta)$$

Ejemplo: Supongamos que X_1, \dots, X_n es una muestra aleatoria de una población con distribución exponencial de parámetro β . sea $f(x) = \frac{1}{\beta} e^{-x/\beta}$, $x > 0$

La densidad conjunta entonces es:

$$f(x_1, \dots, x_n | \beta) = \prod_{i=1}^n f(x_i | \beta) = \frac{1}{\beta^n} e^{-\frac{(x_1 + \dots + x_n)}{\beta}}$$

Podemos calcular la probabilidad que todos los X_i sean mayores a 2 mediante

$$P(X_1 > 2, X_2 > 2, \dots, X_n > 2) = \int_2^{+\infty} \dots \int_2^{+\infty} \frac{1}{\beta^n} e^{-\frac{\sum x_i}{\beta}} dx_1 \dots dx_n$$

$$= \prod_{i=1}^n \left(\int_{-\infty}^{+\infty} \frac{1}{\beta} e^{-x_i/\beta} dx_i \right) = \left(e^{-2/\beta} \right)^n = e^{-2n/\beta}$$

El caso notado en la definición 1 suele llamarse muestreo de una población infinita.

¿Qué sucede cuando se tiene una población finita?

Supongamos que tenemos una población finita $\{x_1, x_2, \dots, x_N\}$. Se toma una muestra X_1, X_2, \dots, X_n de esa población.

Existen dos formas de tomar esa muestra
a) con reemplazamiento b) sin reemplazamiento.

En el caso a) la probabilidad de elegir cada valor de la población en cualquier etapa del muestreo es $1/N$. Es claro que se cumplen las condiciones de la definición 1.

En el segundo caso si $X_1 = x_1$ entonces la probabilidad de $X_2 = x_2$ es 0 para $x_2 \neq x_1$.

probabilidad de $x_2 = x_2$ es \sim para $x_2 = x_1$,
vale $\frac{1}{N-1}$ para $x_2 \neq x_1$

O sea no se satisface la condición de la definición!

Las variables aleatorias X_1, \dots, X_n no son mutuamente independientes pues $P(X_2 = 0 | X_1 = 0) = 0$ y $P(X_2 = 0 | X_1 = x) = \frac{1}{N-1}$

Es interesante ver que X_1, \dots, X_n son idénticamente distribuidos, o sea la distribución (marginal) de X_i es la misma $\forall i = 1, \dots, n$.

Por ejemplo

$$P(X_2 = x) = \sum_{i=1}^N P(X_2 = x | X_1 = x_i) P(X_1 = x_i)$$
$$= (N-1) \frac{1}{N-1} \frac{1}{N} = \frac{1}{N}$$

A veces a este tipo de muestra se le llama muestra aleatoria simple.

Es claro que no se cumple la definición 1 pero si N es grande se está muy cercano a la independencia

Definición 2 Sea X_1, X_2, \dots, X_n una muestra aleatoria de

temario n de una población y sea $T(x_1, \dots, x_n)$ una función a valores reales o vectoriales cuyo dominio incluye el espacio muestral de (X_1, \dots, X_n) . Entonces a $Y = T(X_1, \dots, X_n)$ se le llama estadístico. La función de distribución del estadístico Y es llamada distribución muestral de Y .

Definición 3: Se define la media muestral de X_1, \dots, X_n

como

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{X_1 + \dots + X_n}{n}$$

Definición 4: Se define la varianza muestral mediante

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

La desviación estándar muestral se define como $s = \sqrt{S^2}$

Teorema 5: Consideremos x_1, \dots, x_n números cualesquiera y

sea $\bar{x} = (x_1 + \dots + x_n)/n$. Entonces

$$a) \min_a \sum_{i=1}^n (x_i - a)^2 = \sum_{i=1}^n (x_i - \bar{x})^2$$

$$b) (n-1)S^2 = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - n\bar{x}^2$$

Se deja como ejercicio para el práctico

Teorema 6: Sea X_1, \dots, X_n una muestra aleatoria de una población con media μ y varianza $\sigma^2 < \infty$. Entonces

a) $E(\bar{X}) = \mu$

b) $\text{Var}(\bar{X}) = \sigma^2/n$

c) $E(S^2) = \sigma^2$

Dem: a) $E(\bar{X}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \cdot n \cdot E(X_1) = \mu$

b) $\text{Var}(\bar{X}) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \cdot n \cdot \text{Var}(X_1) = \frac{\sigma^2}{n}$

(en este caso se aplica fuertemente la independencia de las variables X_i)

c) $E(S^2) = E\left(\frac{1}{n-1} \left(\sum_{i=1}^n X_i^2 - n\bar{X}^2\right)\right) = \frac{1}{n-1} (n E(X_1^2) - n E(\bar{X}^2))$

Sabemos que $\sigma^2 = E(X_1^2) - E^2(X_1) = E(X_1^2) - \mu^2$

luego $E(X_1^2) = \sigma^2 + \mu^2$

A la vez $E(\bar{X}^2) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right)^2$

obs
 $V(X) = E(X^2) - E(X)^2$

luego $E(\bar{X}) = \mu$

$$\text{Ademas } E(\bar{X}^2) = E\left(\left(\sum_{i=1}^n X_i / n\right)^2\right) = \left| V(X) = E(X^2) - E(X)^2 \right.$$

$$= E\left(\frac{1}{n^2} \left(\sum_{i=1}^n X_i^2 + \sum_{i \neq j} X_i X_j\right)\right) = \frac{1}{n^2} n E(X_i^2) + \frac{1}{n^2} \sum_{i \neq j} E(X_i)E(X_j)$$

$$= \frac{1}{n} (\sigma^2 + \mu^2) + \frac{1}{n^2} \sum_{i \neq j} \mu^2 = \frac{1}{n} (\sigma^2 + \mu^2) + \frac{n(n-1)}{n^2} \mu^2$$

$$= \frac{\sigma^2}{n} + \frac{\mu^2}{n} + \frac{(n-1)}{n} \mu^2 = \frac{\sigma^2}{n} + \mu^2$$

Reemplazando en $E(S^2)$ obtendremos

$$E(S^2) = \frac{1}{n-1} \left(n (\sigma^2 + \mu^2) - n \left(\frac{\sigma^2}{n} + \mu^2 \right) \right) =$$

$$= \frac{1}{n-1} \left((n-1) \sigma^2 \right) = \sigma^2$$

Definición 7: Convergencia en Probabilidad.

Una sucesión de variables aleatorias X_1, X_2, \dots converge en probabilidad a una variable aleatoria X si para todo $\varepsilon > 0$

$$\lim_{n \rightarrow +\infty} P(|X_n - X| \geq \varepsilon) = 0 \quad \text{o lo que es}$$

equivalente se $\lim_{n \rightarrow +\infty} P(|X_n - \mu| < \varepsilon) = 1$

Teorema 8: (Ley débil de los grandes números)

Sea X_1, \dots variables aleatorias iid con $E(X_i) = \mu$
y $\text{Var}(X_i) = \sigma^2 < \infty$. Definamos $\bar{X}_n = \left(\frac{1}{n}\right) \sum_{i=1}^n X_i$

entonces para todo $\varepsilon > 0$

$$\lim_{n \rightarrow +\infty} P(|\bar{X}_n - \mu| < \varepsilon) = 1$$

o sea \bar{X}_n converge en probabilidad a μ

Dem: Usaremos la desigualdad de Chebyshev

para todo $\varepsilon > 0$

$$P(|\bar{X}_n - \mu| \geq \varepsilon) = P((\bar{X}_n - \mu)^2 \geq \varepsilon^2) \leq \frac{E(\bar{X}_n - \mu)^2}{\varepsilon^2} =$$

$$= \frac{\text{Var} \bar{X}}{\varepsilon^2} = \frac{\sigma^2}{n \varepsilon^2} \xrightarrow{n \rightarrow +\infty} 0 \quad \text{de donde se obtiene la tesis.}$$

Definición 9: (Convergencia casi segura) Una sucesión de variables aleatorias X_1, X_2, \dots converge casi seguramente a una variable aleatoria X si para todo $\varepsilon > 0$

$$P\left(\lim_{n \rightarrow \infty} |X_n - X| < \varepsilon\right) = 1$$

o lo que es lo mismo $P\left(\lim_{n \rightarrow \infty} X_n = X\right) = 1$

$$P\left(\lim_{n \rightarrow \infty} X_n \neq X\right) = 0$$

En el práctico se explorará la diferencia entre las definiciones 7 y 9. Si adelantamos que la convergencia casi segura implica la convergencia en probabilidad

Teorema 10: Ley Fuerte de los grandes números

Sean X_1, X_2, \dots una sucesión de variables aleatorias iid con $E(X_i) = \mu$ y $\text{Var}(X_i) = \sigma^2 < \infty$ y definamos $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$.

Entonces \bar{X}_n converge casi seguramente a μ

Definición 11: Una sucesión de variables aleatorias X_1, \dots converge en distribución a una variable aleatoria X si:

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = F_X(x)$$

para todo punto de continuidad de F_X .

$$\lim_n P(X_n \leq x) = P(X \leq x)$$

Teorema 12: Sea X_1, X_2, \dots converja en probabilidad a X entonces también converge en distribución a X

Por último damos también una versión del teorema central del límite

Teorema 13: Sea X_1, X_2, \dots una sucesión de variables aleatorias con $E(X_i) = \mu$ y $0 < \text{Var} X_i = \sigma^2 < \infty$

Sea $G_n(x)$ la función de distribución de $\sqrt{n}(\bar{X}_n - \mu)/\sigma$
Entonces para todo x ; $-\infty < x < \infty$

$$\lim_{n \rightarrow \infty} G_n(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-y^2/2} dy$$

o sea $\sqrt{n}(\bar{X}_n - \mu)/\sigma$ converge en distribución a la normal típica

Teorema 14 (Slutsky)

Si $X_n \rightarrow X$ en distribución y $Y_n \rightarrow a$ (a cte) en probabilidad, entonces

a) $Y_n X_n \rightarrow aX$ en distribución

b) $X_n + Y_n \rightarrow X + a$ en distribución

Ejemplo Supongamos que se cumple el teorema central del límite μ

$$\frac{\sqrt{n}(\bar{X}_n - \mu)}{\sigma} \rightarrow \mathcal{N}(0, 1)$$

Supongamos que σ es desconocido y que estamos en las condiciones por las que $\sigma/\hat{\sigma}_n \rightarrow 1$ en probabilidad (ver Prácticas 1). Entonces

$$\frac{\sqrt{n}(\bar{X}_n - \mu)}{\hat{\sigma}_n} = \frac{\sigma \sqrt{n}(\bar{X}_n - \mu)}{\hat{\sigma}_n \sigma} \rightarrow \mathcal{N}(0, 1)$$