

INTRODUCCIÓN A LA INFERENCIA

Dr. Cristian Carvajal Muquillaza

Universidad de Playa Ancha



Universidad de
Playa Ancha
Facultad de Ciencias
Naturales y Exactas

**DEPARTAMENTO
DISCIPLINARIO
DE MATEMÁTICA
Y ESTADÍSTICA**



Contenido

- 1 Familia de distribuciones, Parámetros y Estadísticos
- 2 Muestras Aleatorias
- 3 Estadísticos
- 4 Estadísticos de Orden
- 5 Conceptos de convergencia
 - Convergencia en Probabilidad
 - Convergencia en Distribución
- 6 Principios de Reducción de datos



Familia de distribuciones

Definición (Familia de distribuciones)

Una *familia de distribuciones* es un conjunto de la forma:

$$\mathcal{F} = \{f(x; \vec{\theta}) : \vec{\theta} \in \Theta\}$$

Donde:

- 1 $f(x; \vec{\theta})$ es una función de masa o densidad,
- 2 $\vec{\theta}$ es un **vector de parámetros**,
- 3 Θ es el conjunto de posibles valores de $\vec{\theta}$ llamado **Espacio Paramétrico**.

Obs: Si $\vec{\theta} = (\theta_1, \theta_2, \dots, \theta_k)$, entonces $\vec{\theta} \subseteq \mathbb{R}^k$

Familia de distribuciones

Ejemplo: Continuación

Es la Familia llamada de Gauss, más conocida como la **Familia Normal**

- El parámetro $\vec{\theta}$ es **bidimensional**,
- μ es llamado **parámetro de centro** y tiene como espacio paramétrico a $\mathbb{R}$,
- σ^2 es llamado **parámetro de forma** y su espacio paramétrico es $\mathbb{R}^+$.

Zoom

- 1 $\vec{\theta}$ por lo general es desconocido,
- 2 La Inferencia Estadística permite estimar los valores de $\vec{\theta}$.

Familia de distribuciones

Ejemplo:

La población de estaturas de los habitantes de una país se asume con distribución Normal, es decir si X es la variable aleatoria definida como “**Estatura de los habitantes de la población**”, entonces:

$$X \sim N(\mu; \sigma^2)$$

El problema consiste en obtener información de los parámetros μ y σ^2 , la técnica básica consiste en reiterar observaciones de los individuos de la población bajo las mismas condiciones. El concepto que se define a continuación formaliza esta idea.



Muestras Aleatorias

Muestras Aleatorias

Las variables aleatorias $\underline{X} = (X_1, X_2, \dots, X_n)$ son llamadas **MUESTRAS ALEATORIAS** de tamaño n desde la población $f(x)$ si $X_1, X_2, \dots, X_n$ son variables aleatorias mutuamente independientes y las funciones marginales de densidad o masa de cada X_i tiene la misma función $f(x)$, lo que normalmente se llama **variables aleatorias independientes e idénticamente distribuida**, lo que se abrevia variables iid.

Zoom

$\underline{X} = (X_1, X_2, \dots, X_n)$ *ma(n)* de X significa

- 1 X_i independiente de $X_j, \forall i \neq j$ (Independencia)
- 2 $X_i \sim X, \forall i$ (Equidistribución).

Muestras Aleatorias

Definición (Muestra Aleatoria)

Sea $\underline{X} = (X_1, X_2, \dots, X_n)$ una m.a (n), desde una población $f(x)$, entonces la conjunta $f_{\underline{X}}(\underline{x})$ es igual al producto de las marginales, es decir:

$$\begin{aligned} f_{\underline{X}}(\underline{x}) &= f_{X_1}(x_1) \cdot f_{X_2}(x_2) \cdot \dots \cdot f_{X_n}(x_n) \\ &= \prod_{i=1}^n f(x_i) \end{aligned}$$



Muestras Aleatorias

Ejemplo:

Sean $\underline{X} = (X_1, X_2, \dots, X_n)$ una m.a (n), desde una población con distribución Poisson de parámetro λ , es decir $X \sim P(\lambda)$, con función de masa

$$f(x; \lambda) = \frac{e^{-\lambda} \lambda^x}{x!}$$

Resp:

$$\begin{aligned} f_{\underline{X}}(\underline{x}; \lambda) &= \prod_{i=1}^n \frac{e^{-\lambda} \lambda^{x_i}}{x_i!} \\ &= \frac{e^{-n\lambda} \lambda^{\sum_{i=1}^n x_i}}{\prod_{i=1}^n x_i!} \end{aligned}$$

Muestras Aleatorias

Zoom

La función $f_{\underline{X}}(\underline{x}; \lambda)$ es llamada **Función de $\underline{X}$ Verosimilitud**, y algunas veces se denota

$$L(\underline{X}; \vec{\theta}) \quad \vee \quad L(\vec{\theta}; \underline{X})$$



Estadísticos

Definición (Estadístico)

Sean $\underline{X} = (X_1, X_2, \dots, X_n)$ una muestra aleatoria de tamaño n , desde una población y sea $T(\underline{X})$ una función a valor real o a valor vectorial cuyo dominio está incluido en el espacio muestral de $\underline{X}$, entonces la variable aleatoria o vector aleatorio $Y = T(\underline{X}) = T(X_1, X_2, \dots, X_n)$ es llamado **Estadístico**, si $T(\underline{X})$ sólo depende de los componentes de $\underline{X}$.



Estadísticos

Ejemplo:

Supona que se está muestreando una variable aleatoria $X \sim N(\mu; \sigma^2)$.
Determinar si las siguientes funciones son Estadísticos:

1 $T(\underline{X}) = \frac{1}{n} \sum_{i=1}^n x_i$

2 $T(\underline{X}) = 2x_1 + \mu x_2$

3 $T(\underline{X}) = \sum_{i=1}^n x_i$

4 $T(\underline{X}) = \prod_{i=1}^n x_i$

5 $T(\underline{X}) = \frac{\sigma^2}{n-1} \sum_{i=1}^n x_i$

Estadísticos

Algunos Estadísticos Importantes:

Desviación Estándar Muestral

$$T(\underline{X}) = S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

Mínimo

$$T(\underline{X}) = x_{(1)}$$

Máximo

$$T(\underline{X}) = x_{(n)}$$

AMENTO
NARIO
MÁTICA

— Naturales y Exactas | Y ESTADÍSTICA



Estadísticos

Teorema

Sean $X_1, X_2, \dots, X_n$ una m.a (n), y $\bar{X}$ la media muestral, entonces:

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



Estadísticos

Lema

Sean $X_1, X_2, \dots, X_n$ una m.a (n) desde una población y sea $g(x)$ una función tal que $E(g(X_1))$ y $Var(g(X_1))$ existen, entonces:

- 1 $E\left(\sum_{i=1}^n g(X_i)\right) = nE(g(X_1))$
- 2 $Var\left(\sum_{i=1}^n g(X_i)\right) = nVar(g(X_1))$



Estadísticos

Teorema

Sean $X_1, X_2, \dots, X_n$ una m.a (n), desde una población con media μ y varianza $\sigma^2 < \infty$, entonces:

$$1 \quad E(\bar{X}) = \mu$$

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

$$3 \quad E(S^2) = \sigma^2$$



Estadísticos de Orden

Definición (Estadísticos de Orden)

Los estadísticos de orden de una muestra aleatoria $(X_1, X_2, \dots, X_n)$ son los valores muestrales ordenados de forma creciente, los cuales son denotados por $X_{(1)}, X_{(2)}, \dots, X_{(n)}$, donde:

$$X_{(1)} = \min_{1 \leq i \leq n} X_i$$

$$X_{(2)} = \text{Segundo más pequeño } X_i$$

$$\vdots$$

$$X_{(n)} = \max_{1 \leq i \leq n} X_i$$

Estadísticos de Orden

Teorema (Estadísticos de Orden)

Sean $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ estadísticos de orden de una muestra aleatoria $(X_1, X_2, \dots, X_n)$, desde una población con cdf $F_X(x)$ y pdf $f_X(x)$, entonces la pdf de $X_{(j)}$ es:

$$f_{X_{(j)}}(x_{(j)}) = \frac{n!}{(j-1)!(n-j)!} f_X(x) [F_X(x)]^{j-1} [1 - F_X(x)]^{n-j}$$



Estadísticos de Orden

Teorema (Estadísticos de Orden)

Sean $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ estadísticos de orden de una muestra aleatoria $(X_1, X_2, \dots, X_n)$, desde una población con cdf $F_X(x)$ y pdf $f_X(x)$, entonces la pdf conjunta de $X_{(i)}$ y $X_{(j)}$; $1 \leq i < j \leq n$ es:

$$f(x_{(i)}, x_{(j)}) = \frac{n!}{(i-1)!(j-1-i)!(n-j)!} f(u) f(v) [F(u)]^{i-1} \\ \times [F(v) - F(u)]^{j-1-i} [1 - F(v)]^{n-j}$$



Conceptos de convergencia

Teorema (Convergencia en Probabilidad)

Una sucesión $\{X_n\}_{n \in \mathbb{N}}$ de variables aleatorias **converge en probabilidad** a la variable aleatoria X , lo que se denota $X_n \xrightarrow{p} X$ si: $\forall \varepsilon > 0$;

$$\lim_{n \rightarrow \infty} P(|X_n - X| \geq \varepsilon) = 0 \quad \vee \quad \lim_{n \rightarrow \infty} P(|X_n - X| < \varepsilon) = 1$$



Supongamos que tenemos una sucesión de variables aleatorias $\{X_n\}_{n \in \mathbb{N}}$ donde $X_n \sim \text{Uniforme}(0, \frac{1}{n})$. Queremos verificar si esta sucesión converge en probabilidad a cero, es decir, si $X_n \xrightarrow{P} 0$ cuando $n \rightarrow \infty$. Para demostrar la convergencia en probabilidad, usamos la definición:

$$\lim_{n \rightarrow \infty} P(|X_n - 0| \geq \varepsilon) = \lim_{n \rightarrow \infty} P(X_n \geq \varepsilon)$$

Dado que $X_n \sim \text{Uniforme}(0, \frac{1}{n})$, la probabilidad de que $X_n \geq \varepsilon$ es igual a $\frac{1}{n\varepsilon}$ para $\varepsilon < \frac{1}{n}$ y 0 en otro caso. Por lo tanto,

$$\lim_{n \rightarrow \infty} P(X_n \geq \varepsilon) = \lim_{n \rightarrow \infty} \frac{1}{n\varepsilon} = 0$$

para cualquier $\varepsilon > 0$. Así, demostramos que $X_n \xrightarrow{P} 0$ cuando $n \rightarrow \infty$.



Supongamos que tenemos una sucesión de variables aleatorias $\{Y_n\}_{n \in \mathbb{N}}$ donde $Y_n \sim \text{Normal}(0, \frac{1}{n})$. Queremos verificar si esta sucesión converge en probabilidad a cero, es decir, si $Y_n \xrightarrow{P} 0$ cuando $n \rightarrow \infty$.

Para demostrar la convergencia en probabilidad, utilizamos la definición:

$$\lim_{n \rightarrow \infty} P(|Y_n - 0| \geq \varepsilon) = \lim_{n \rightarrow \infty} P(|Y_n| \geq \varepsilon)$$

Dado que $Y_n \sim \text{Normal}(0, \frac{1}{n})$, la probabilidad $P(|Y_n| \geq \varepsilon)$ para cualquier $\varepsilon > 0$ es:

$$P(|Y_n| \geq \varepsilon) = 2 \cdot \Phi(-\sqrt{n}\varepsilon)$$

donde $\Phi(\cdot)$ es la función de distribución acumulada de la distribución normal estándar.

Entonces, $\lim_{n \rightarrow \infty} P(|Y_n| \geq \varepsilon) = 0$ ya que $\sqrt{n}\varepsilon \rightarrow \infty$ cuando $n \rightarrow \infty$.

Por lo tanto, demostramos que $Y_n \xrightarrow{P} 0$ cuando $n \rightarrow \infty$.



Conceptos de convergencia

Ejemplo:

Sea $X_n \sim \text{Exp}(n)$, pruebe que $X_n \xrightarrow{p} 0$. Es decir, la sucesión $X_1, X_2, \dots$ converge en probabilidad a la variable aleatoria $X = 0$

Respuesta:

$$\begin{aligned}\lim_{n \rightarrow \infty} P(|X_n - 0| \geq \varepsilon) &= \lim_{n \rightarrow \infty} P(|X_n| \geq \varepsilon) \\ &= \lim_{n \rightarrow \infty} P(X_n \geq \varepsilon) \quad (\text{ya que } X_n \geq 0) \\ &= \lim_{n \rightarrow \infty} e^{-n\varepsilon} \quad (\text{ya que } X_n \sim \text{Exp}(n)) \\ &= 0\end{aligned}$$

Conceptos de convergencia

Teorema (Ley débil de los grandes números)

Sean $X_1, X_2, \dots$ variables aleatorias iid con $\mathbb{E}(X_i) = \mu$ y $\text{Var}(X_i) = \sigma^2 < \infty$, y se define $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$, entonces $\forall \varepsilon > 0$;

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

Esto es que $\bar{X}_n$ **converge en probabilidad** a μ , es decir

$$\bar{X}_n \xrightarrow{p} \mu.$$



Conceptos de convergencia

Teorema (Ley fuerte de los grandes números)

Sean $X_1, X_2, ..$ variables aleatorias iid con $\mathbb{E}(X_i) = \mu$ y $Var(X_i) = \sigma^2 < \infty$, y se define $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$, entonces $\forall \varepsilon > 0$;

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

Esto es que $\bar{X}_n$ converge de forma casi segura hacia μ .



Conceptos de convergencia

Definición (Convergencia en Distribución)

Una sucesión de variables aleatorias $X_1, X_2, ..$ **converge en distribución** a la variable aleatoria X si:

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

en todos los puntos x donde $F_X(X)$ es continua.



Teorema Central del Límite

Teorema (Teorema Central del Límite)

Sean $X_1, X_2, \dots$ variables aleatorias iid con $\mathbb{E}(X_i) = \mu$ y $\text{Var}(X_i) = \sigma^2 < \infty$, y se define $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Sea $G_n(x)$ la función de distribución de $\frac{\sqrt{n}(\bar{X}_n - \mu)}{\sigma}$. Entonces

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

Esto es, $\frac{\sqrt{n}(\bar{X}_n - \mu)}{\sigma}$ converge en distribución a una Normal Estándar.

Principios de Reducción de datos

Principio de suficiencia

Un estadístico suficiente para un parámetro θ es uno que, de cierta forma, captura toda la información acerca de θ contenida en la muestra. No es posible obtener información adicional en la muestra, además del valor del estadístico suficiente. Estas consideraciones nos llevan a la técnica de reducción de datos conocida como el principio de suficiencia: “si $T(X)$ es un estadística suficiente para θ , entonces el proceso de inferencia sobre θ depende de la muestra X solo a través del valor $T(X)$ ”.



Principios de Reducción de datos

Definición (Estadístico Suficiente)

*Una estadístico $T(X)$ es una **estadístico suficiente** para θ si la distribución de la muestra X dado el valor de $T(X)$ no depende de θ .*

Teorema (Estadístico Suficiente)

Si $f(x|\theta)$ es la función de probabilidad o densidad conjunta de X , y $q(t|\theta)$ es la función de probabilidad o densidad de $T(X)$, entonces $T(X)$ es un estadístico suficiente para θ si y solo si:

$$\frac{f(x|\theta)}{q(T(x)|\theta)}$$

no depende de θ para todo X .

Principios de Suficiencia

Ejemplo: CONTINUACIÓN

Como $T(x) = (X_1 + \dots + X_n)$, suma de Bernoulli es una binomial, por lo que

$$q(T(x|\theta)) = \binom{n}{t} \theta^t (1 - \theta)^{n-t} \quad ; \quad t = \sum_{i=1}^n x_i$$

luego se tiene

$$\frac{f(x|\theta)}{q(T(x|\theta))} = \frac{\theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i}}{\binom{n}{t} \theta^t (1 - \theta)^{n-t}}$$



Principios de Suficiencia

Ejemplo: CONTINUACIÓN

$$\begin{aligned}\frac{f(x|\theta)}{q(T(x|\theta))} &= \frac{\theta^t (1 - \theta)^{n-t}}{\binom{n}{t} \theta^t (1 - \theta)^{n-t}} \\ &= \frac{1}{\binom{n}{t}} \\ &= \frac{1}{\binom{n}{\sum_{i=1}^n x_i}}\end{aligned}$$

Entonces, como la razón no depende de θ , $T(X)$ es un ESTADÍSTICO SUFICIENTE para θ .

Principios de Suficiencia

Teorema (Teorema de Factorización)

Sea $f(x|\theta)$ la pdf o pmf conjunta de una muestra X . Un estadístico $T(x)$ es un estadístico suficiente para θ si y sólo si existen funciones $g(t|\theta)$ y $h(x)$ tales que:

$$f(x|\theta) = g(T(X)|\theta) \cdot h(x)$$

