Inferencia Estadística

Población y muestra

Conceptos y definiciones

Alice Kelley (c) 1999

Si seleccionamos una muestra con reemplazamiento, de seis estudiantes de la población, para observar la edad de cada uno, entonces definiremos seis variables aleatorias:

X_1: edad del primer estudiante seleccionado.
X_2: edad del segundo estudiante seleccionado,
$\vdots$
X_6: edad del sexto estudiante seleccionado

Cada variable aleatoria tendrá una distribución de probabilidad asociada. Así pues, la distribución de la variable aleatoria X, será exactamente la misma que la distribución de la variable aleatoria X sin reemplazamiento ya que ambas variables aleatorias se refieren a la edad de un estudiante seleccionado al azar.

Pero como el muestreo se ha realizado con reemplazamiento, se puede ver lo siguiente:

- ***La variable aleatoria X_2, tiene la misma distribución de probabilidades que* X o que X_1.**
- ***X_2, y X, son independientes. De igual forma, las variables* aleatorias *X_3, X_4, X_5, y X_6, tienen la misma distribución que X, y en consecuencia* la sucesión de variables aleatorias *X_1, X_2, ..., X_6, son independientes e* idénticamente distribuidas.**

Definición MAS

*Sea **X** la variable aleatoria correspondiente a una población con función de distribución **F(x)**. Si las variables aleatorias X_1, X_2, ..., X_n, son <u>independientes</u> y tienen la <u>misma función de distribución</u>, **F(x)**, que la de la distribución de la población, entonces las variables aleatorias X_1, X_2, ..., X_n, forman un conjunto de variables aleatorias independientes e idénticamente distribuidas que constituyen una muestra aleatoria simple de tamaño **n** de la población F (x)*

Al ser las variables aleatorias ***X_1, X_2, ..., X_n, independientes,*** resulta que la función de distribución conjunta será igual al producto de las funciones de distribución marginales, es decir:

Regla (□)

Regla (□)

$$F(x_1,\ x_2,\cdots x_n) = \prod_{i=1}^{n} F(x_i)$$

Si la población de partida es de tipo discreto y la función de probabilidad de la población es:

$$p_i = P(X = x_i) \qquad \forall\ i = 1,\ 2,\cdots,n$$

entonces la función de probabilidad de la muestra será:

$$P(X_1 = x_1, X_2 = x_2, \cdots X_n = x_n) = \prod_{i=1}^{n} P(X = x_i) = \prod_{i=1}^{n} p_i$$

Si la muestra aleatoria simple procede de una población de tipo continuo con función de densidad f(x), entonces la función de densidad de la muestra será:

$$f(x_1, x_2, \cdots x_n) = \prod_{i=1}^{n} f(x_i)$$

Ejemplo 2

Sea $X_1,\dots X_n$, una MAS de n variables, de un a población cuya distribución de probabilidad es exponencial con densidad dada por

$$f(x,\theta)=\frac{1}{\theta}e^{\frac{-x}{\theta}}\ \forall\ 0<x<\infty$$

Cuando X_1 se observa se registra la realización x_1

$$f(x_1,\theta)=\frac{1}{\theta}e^{\left\{-x_1/\theta\right\}}\ \forall\ 0<x_1<\infty$$

Se observa X_2 se registra la realización x_2. Pero dado que son estadísticamente independientes y tienen la misma densidad

$$f(x_2\mid x_1)=f(x_2)=\frac{1}{\theta}e^{\left\{-x_2/\theta\right\}}\ \forall\ 0<x_2<\infty$$

La función de densidad conjunta X_1y X_2 es

$$f(x_1,x_2,\theta)=f(x_1,\theta)f(x_2,\theta)=$$

$$=\frac{1}{\theta^2}e^{\left\{-(x_1+x_2)/\theta\right\}}\ \forall\ 0<x_i<\infty$$

Y se deduce entonces la extención a X_1 … X_n es:

Parámetros Poblacionales

- Estadísticos muéstrales

Definición

Los parámetros poblacionales son las características numéricas de la población. Un parámetro es una caracterización numérica de la distribución de la población. El conocimiento del parámetro permite describir parcial o totalmente la función de probabilidad de la característica que estamos investigando. Por ejemplo, si la característica a investigar sabemos que sigue una distribución exponencial de parámetro *a* su función de densidad está determinada.

$$f(x) = \begin{cases} ae^{-a} & x < 0 \\ 0 & x \leq 0 \end{cases}$$

Dicha función de densidad no estará totalmente descrita hasta que no se dé el valor del parámetro *a*, y entonces será cuando podremos formular preguntas concretas sobre esa distribución, es decir, podremos calcular las diferentes probabilidades.

Si la característica a investigar sigue una distribución normal, $N(\mu,\sigma)$, la función de densidad contiene dos parámetros, para describir totalmente la función de densidad tendremos que dar valores a μ y a σ, pues si damos valor sólo a un parámetro entonces diremos que está descrita parcialmente.

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Comprendo

En la mayoría de los modelos probabilísticos nos encontraremos parámetros cuyos valores tendremos que fijar para especificar completamente el modelo y poder calcular las probabilidades deseadas. Uno de los problemas centrales en estadística se presenta cuando deseamos estudiar una población con función de distribución $F(x, \theta)$, donde la forma de la función de distribución es conocida, pero depende del parámetro θ desconocido, ya que si θ fuese conocido tendríamos totalmente especificada la función de distribución. Si el parámetro θ no se conoce entonces se selecciona una muestra aleatoria simple $(X_1,\ldots, X_n)$ de tamaño n de la población, y se calcula para las observaciones de la muestra el valor de alguna función $g(x_1, \ldots, x_n)$, que representa o estima el parámetro desconocido θ. El problema es determinar qué función será la mejor para estimar el parámetro θ.

Definición Estadístico

Un estadístico es cualquier función real de las variables aleatorias que integran la muestra, es decir, es una función de las observaciones muestrales, la cual no contiene ningún valor o parámetro desconocido.

- Identificamos la población con función de distribución ***F(x, θ)***
- Consideramos una MAS constituida por n variables (AIUD) ***(X_1, …, X_n)***

Es posible definir algunos estadísticos o funciones de esas variables aleatorias, como por ejemplo:

$$g_1(X_1, \cdots X_n) = \frac{X_1 + X_2 + \cdots X_n}{n}$$

$$g_2(X_1, \cdots X_n) = \frac{X_1^2 + X_2^2 + \cdots X_n^2}{n}$$

$$g_3(X_1, \cdots X_n) = \frac{\left(X_1 - \overline{X}\right)^2 + \left(X_2 - \overline{X}\right)^2 + \cdots \left(X_n - \overline{X}\right)^2}{n}$$

Los estadísticos se determinan siempre a partir de lobservaciones muestrales.

Definición Estadístico

De forma general al estadístico lo representaremos por la letra ***T***, es decir:

$$T = g(X_1, \cdots X_n)$$

La función g() será la función que describa las observaciones muestrales, asimismo será una variable aleatoria, ya que para cada muestra, el estadístico ***T*** tomará un valor distinto. Entonces para una muestra de n observaciones $\boldsymbol{(x_1, \ldots, x_n)}$el estadístico tomará el valor

$$T = g(x_1, \cdots x_n)$$

Se toman distintas muestras y desde luego se obtienen valores diferentes para el estadístico, resultando entonces que efectivamente el estadístico T , también es una variable aleatoria, Ahora bien, si es una variable aleatoria, entonces también pose su función de distribución, la cual se llama Función de Distribución Muestral del Estadístico

Un parámetro y un estadístico son conceptos diferentes, pues el parámetro es una constante Y el estadístico es una variable aleatoria.

Hemos estudiado diferentes medidas numéricas correspondientes a conjuntos de datos, entre otras, estudiamos la media, la desviación estándar etc. Ahora vamos a distinguir entre medidas numéricas calculadas con conjuntos de datos poblacionales y las calculadas con datos muestrales. Si la medida numérica se calcula para el conjunto de datos poblacionales le llamaremos valor del parámetro poblacional y si se calcula para el conjunto, de datos muestrales, le llamaremos valor del estadístico muestral.

Parámetros

En una población finita de tamaño N los parámetros poblacionales **media**, **varianza** y **proporción poblacional** vienen dados por:

$$\mu = \frac{1}{N}\sum_{i=1}^{N} X_i$$

$$\sigma^2 = \frac{1}{N}\sum_{i=1}^{N}(X_i - \mu)^2$$

$$p = \frac{X}{N} = \frac{\#ENP}{\#P}$$

Estadísticos

Para una muestra aleatoria simple de tamaño n, $(X_1, \ldots, X_n)$ los estadísticos: **media**, **varianza** y **proporción muestral** se definen como:

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

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

$$p = \frac{X}{n} = \frac{\#EnP}{\#P}$$

Si en vez de considerar las n variables aleatorias, independientes e idénticamente distribuidas (X_1, ..., X_n) que constituyen la muestra aleatoria simple, consideramos una muestra concreta (x_1, ..., x_n) entonces los valores de estos estadísticos muestrales tomarían la siguiente forma:

$$\overline{x} = \frac{1}{n}\sum_{i=1}^{n} x_i$$

$$x^2 = \frac{1}{n-1}\left(x_i - \overline{x}\right)^2$$

$$\hat{p} = \frac{x}{n} = \frac{\# EnP}{\# P}$$

Veremos que efectivamente el estadístico es una función de las observaciones muestrales, y en estos casos asigna a cada muestra observada la media de los valores, la varianza o la proporción, respectivamente.