

Probabilidad y Estadística

Agustín G. Bonifacio



UNSL

Estadística: Descripción de Datos con Medidas Numéricas

Pretendemos describir o predecir la conducta de la población con base en la información obtenida a partir de una muestra representativa de esa población.

Definición

La **estadística descriptiva** consta de los procedimientos usados para resumir y describir las características importantes de un conjunto de medidas.

Definición

La **estadística inferencial** consiste en los procedimientos que se aplican para plantear inferencias con respecto a las características de la población a partir de la información contenida en una muestra tomada de esa población.

El objetivo de la estadística inferencial es hacer inferencias (conclusiones, predicciones, toma de decisiones) con respecto a las características de una población a partir de la información contenida en una muestra.

Pasos necesarios para lograr el objetivo de la Estadística Inferencial

- 1 Especificar preguntas que se deben plantear e identificar la población de interés.
- 2 Decidir cómo seleccionar la muestra.
- 3 Seleccionar la muestra y analizar la información de la muestra.
- 4 Usar la información del paso anterior para hacer inferencias con respecto a la población.
- 5 Determinar la confiabilidad de la inferencia.

Definición

Las medidas numéricas descriptivas relacionadas con una población de mediciones se llaman **parámetros**, aquellas calculadas desde una muestra de mediciones se llaman **estadísticos**.

Definición

La **media aritmética o promedio** de una lista x_1, \dots, x_n de n mediciones viene dada por

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

Observaciones

- Un uso importante de \bar{x} es como estimador de μ , la media poblacional.
- \bar{x} varía con cada muestra.

Definición

La **mediana** de una lista x_1, \dots, x_n de n mediciones es el valor que se encuentra en la posición central cuando las mediciones están ordenadas de menor a mayor.

Observaciones

- Cuando n es par, la *mediana* se toma como el promedio de los dos valores centrales.
- La *mediana* es menos sensible a los valores extremos o atípicos que la *media*.

Definición

La **moda** de una lista x_1, \dots, x_n de n mediciones es el valor que se presenta con más frecuencia.

Definición

El **rango** de una lista de n mediciones se define como la diferencia entre la medición mayor y la menor.

Definición

La **varianza (muestral)** de una lista de n mediciones x_1, \dots, x_n se define mediante la fórmula

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

Definición

La **desviación estándar** de una lista de n mediciones x_1, \dots, x_n es igual a la raíz cuadrada (positiva) de la varianza.

Definición

Dadas n mediciones ordenadas de menor a mayor, el p -ésimo percentil es el valor que excede $p\%$ de las mediciones y es menor que el restante $(100 - p)\%$.

Definición

- El 25-percentil se denomina **cuartil inferior**, Q_1 .
- El 50-percentil es la mediana.
- El 75-percentil se denomina **cuartil superior**, Q_3 .

Ejemplo

Determine los cuartiles inferior y superior para el siguiente grupo de mediciones:

16, 25, 4, 18, 11, 13, 20, 8, 11, 9.

Definición

El **rango intercuartil, IQR** para un grupo de mediciones es
 $IQR = Q_3 - Q_1$.

Definición

El **resumen de 5 números** de un grupo de n mediciones x_1, \dots, x_n viene dado por

$$\text{mín } x_i, Q_1, \bar{x}, Q_3, \text{máx } x_i.$$

Definición

La **puntuación z** de una observación x mide la distancia de una observación al promedio, en unidades de desviación estándar, esto es,

$$z = \frac{x - \bar{x}}{s}.$$

Definición

Se dice que un estimador $\hat{\theta}$ de un parámetro θ es **insesgado** si $E(\hat{\theta}) = \theta$.

Definición

La distancia entre una estimación y el parámetro estimado se llama **error de estimación**.

De ahora en más suponemos que los tamaños de las muestras son *grandes*, por lo que los estimadores insesgados que estudiaremos tienden a distribuirse de forma normal, como consecuencia del Teorema Central del Límite.

Definición

El **margen de error** (ME) del estimador viene dado por:

$$ME = 1,96 SE$$

donde SE denota el error estándar del estimador.

Ejemplo

Para estimar la media poblacional μ , el estimador \bar{x} es insesgado y tiene error estándar dado por

$$SE = \frac{\sigma}{\sqrt{n}}.$$

Entonces

$$ME = \pm 1,96 \frac{\sigma}{\sqrt{n}}.$$

Si no se conoce σ y $n \geq 30$, se puede aproximar σ con s .

Ejemplo

Para estimar la proporción poblacional p en una población binomial, el estimador $\hat{p} = x/n$ es insesgado con

$$SE = \sqrt{\frac{p(1-p)}{n}},$$

por lo cual

$$ME = \pm 1,96 \sqrt{\frac{p(1-p)}{n}},$$

que se estima como

$$\pm 1,96 \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}.$$

Definición

Un **estimador por intervalo** es una regla para calcular dos números a y b que crean un intervalo $[a, b]$ que contiene con una probabilidad de $(1 - \alpha)$ al parámetro de interés. El número $(1 - \alpha)$ se denomina **coeficiente de confianza**.

¿Cómo se construye un intervalo de confianza?

Intervalo de confianza de $(1 - \alpha)100\%$ para una muestra grande

$$\text{Estimador Puntual} \pm z_{\alpha/2}SE$$

Ejemplo

Intervalo de confianza de $(1 - \alpha)100\%$ para la media poblacional μ de una muestra grande

$$\bar{x} \pm z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$$

donde n es el tamaño de la muestra y σ es la desviación estándar de la población. Cuando no se conoce σ , se puede aproximar mediante s .

Observación

Notemos que lo anterior es equivalente a escribir

$$P \left(\left[\bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} < \mu < \bar{x} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right] \right) = 1 - \alpha.$$

Ejemplo

Intervalo de confianza de $(1 - \alpha)100\%$ para una proporción poblacional p en una muestra grande

$$\bar{p} \pm z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}$$

donde n es el tamaño de la muestra.

Observación

Un buen intervalo de confianza debe cumplir:

- 1 Ser tan estrecho como sea posible.
- 2 Tener un coeficiente de confianza grande, cercano a 1.

Límite de confianza inferior de $(1 - \alpha)100\%$:

$$\text{Estimador Puntual} - z_{\alpha}SE$$

Límite de confianza superior de $(1 - \alpha)100\%$:

$$\text{Estimador Puntual} + z_{\alpha}SE$$