

3) Inferencia en poblaciones normales

3.1) Inferencia sobre μ con σ^2 conocido

$$\text{Sea } \tilde{x} = N(\mu; \sigma^2) \quad \Rightarrow \quad \bar{x} = N\left(\mu; \frac{\sigma^2}{n}\right)$$

$$\text{luego } z = \frac{\bar{x} - \mu}{\sigma / \sqrt{n}} = N(0;1)$$

3.2) Inferencia sobre μ con σ^2 desconocido

$$\text{Sea } \tilde{x} = N(\mu; \sigma^2)$$

Puede estimarse σ^2 a partir de la muestra, mediante $s^2 = \frac{1}{v} \sum_{i=1}^N (x_i - \bar{x})^2$, con $v = n - 1$

grados de libertad.

$$\text{Estadístico: } t_v = \frac{\bar{x} - \mu}{s / \sqrt{n}} \quad (\text{tiene distribución t-Student})$$

3.3) Inferencia sobre σ^2

Estadístico $\chi^2 = \frac{v \cdot s^2}{\sigma^2}$ (tiene distribución ji-cuadrado con $v = n - 1$ grados de libertad)

Cuando se tienen m muestras se amalgaman las varianzas:

$$\chi^2 = \sum_{i=1}^n \sum_{j=1}^n \left(\frac{x_{ij} - \bar{x}_i}{\sigma} \right)^2 = \sum_{i=1}^n v_i \cdot \frac{s_i^2}{\sigma^2}$$

Tomando la varianza amalgamada $s^2 = \frac{1}{v} \sum_{i=1}^n v_i \cdot s_i^2$ con $v = \sum v_i$ grados de

libertad queda $\chi^2 = v \cdot \frac{s^2}{\sigma^2}$

3.4) Comparación de poblaciones normales

3.4.1) Comparación de varianzas

Sean $\tilde{x}_1 = N(\mu; \sigma^2)$ y $\tilde{x}_2 = N(\mu; \sigma^2)$ independientes

Estadístico: $F_{v_1, v_2} = \frac{1}{\varphi^2} \cdot \frac{s_1^2}{s_2^2}$ (tiene distribución F-Snedecor). Donde $\varphi^2 = \frac{\sigma_1^2}{\sigma_2^2}$ con

$v_1 = \text{g.l. del numerador}$ y $v_2 = \text{g.l. del denominador}$

3.4.2) Comparación de medias

Sean $\tilde{x}_1 = N(\mu_1; \sigma^2)$ y $\tilde{x}_2 = N(\mu_2; \sigma^2)$ independientes. Interesa inferir sobre el valor de

$$\delta = \mu_1 - \mu_2$$

$$\text{Estadístico: } d = \bar{x}_1 - \bar{x}_2$$

3.4.2.1) Muestra no apareada con varianzas conocidas

Como d es una combinación lineal de \bar{x}_1 y \bar{x}_2

$$u = \frac{d - \delta}{\sigma_{\Delta}} = N(0;1) \quad \text{siendo} \quad \begin{aligned} d &= \bar{x}_1 - \bar{x}_2 \\ \delta &= \mu_1 - \mu_2 \end{aligned} \quad \text{y} \quad \sigma_{\Delta}^2 = \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}$$

3.4.2.2) Muestra no apareada con varianzas desconocidas

- **Caso Homocedástico (clásico):** $\sigma_1^2 = \sigma_2^2$

$$\text{Estadístico: } t_{v_{\Delta}} = \frac{d - \delta}{\frac{s}{\sqrt{n_e}}} \quad \text{siendo} \quad \begin{aligned} d &= \bar{x}_1 - \bar{x}_2 \\ \delta &= \mu_1 - \mu_2 \end{aligned}$$

$$v_{\Delta} = n_1 + n_2 - 2 \quad \frac{1}{n_e} = \frac{1}{n_1} + \frac{1}{n_2} \quad s^2 = \frac{v_1 \cdot s_1^2 + v_2 \cdot s_2^2}{v_1 + v_2}$$

- **Caso Heterocedástico (Welch):** $\sigma_1^2 \neq \sigma_2^2$

$$\text{Estadístico } t_v = \frac{d - \delta}{s} \quad \text{siendo} \quad \begin{aligned} d &= \bar{x}_1 - \bar{x}_2 \\ \delta &= \mu_1 - \mu_2 \end{aligned}$$

$$s^2 = \frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}$$

$$v = \left[\frac{1}{v_1} \cdot \left(\frac{n_2 \cdot s_1^2}{n_2 \cdot s_1^2 + n_1 \cdot s_2^2} \right)^2 + \frac{1}{v_2} \cdot \left(\frac{n_1 \cdot s_2^2}{n_2 \cdot s_1^2 + n_1 \cdot s_2^2} \right)^2 \right]^{-1}$$

3.4.2.3) Muestra apareada

Las variables son dependientes. Puede considerarse normal la diferencia entre las mismas.

$$\text{Sean } \begin{aligned} \tilde{x}_1 &= N(\mu_1; \sigma_1^2) \\ \tilde{x}_2 &= N(\mu_2; \sigma_2^2) \end{aligned} \quad \text{donde } \mu_1 \text{ y } \mu_2 \text{ varían dato a dato}$$

$$\text{manteniendo } \mu_1 - \mu_2 = c \quad \text{y} \quad \tilde{d} = \tilde{x}_1 - \tilde{x}_2 = N(\delta; \sigma_d^2)$$

HOJAS DE FÓRMULAS

$$\text{Estadístico: } t_v = \frac{\bar{d} - \delta}{\frac{s_d}{\sqrt{n}}} \quad \text{con } v = n - 1$$

3.5) Inferencia sobre ρ

Sea $(\tilde{x}; \tilde{y}) = N(\mu_x; \mu_y; \sigma_x^2; \sigma_y^2)$ Normal Bidimensional

Si $\rho=0$

$$\text{Estadístico: } t_v = r \cdot \sqrt{\frac{n-2}{1-r^2}} \quad \text{con } v = n - 2$$

$$\text{donde } r = \frac{s_{xy}}{s_x \cdot s_y}$$

$$s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y}) = \frac{1}{n-1} \sum_{i=1}^n x_i \cdot y_i - n \cdot \bar{x} \cdot \bar{y}$$

Para inferir acerca de $\rho=\rho_0$

Estadístico (aproximación de Fisher) $z = \frac{1}{2} \cdot \ln\left(\frac{1+r}{1-r}\right) \cong N(\mu_z; \sigma_z^2)$ con

$$\mu_z = \frac{1}{2} \cdot \ln\left(\frac{1+\rho}{1-\rho}\right) \quad \sigma_z^2 = \frac{1}{n-3}$$

4) Regresión**4.1) Regresión Lineal Simple**

$$\text{Modelo: } \tilde{y}_i = \beta_0 + \beta_1 \cdot x_i + \tilde{\varepsilon}_i \quad i = 1, 2, \dots, n$$

\tilde{y} : variable que se desea estudiar

x : variable que se utilizará para explicar a \tilde{y}

β_0 y β_1 : parámetros de la función lineal que vincula a \tilde{y} con x

$\tilde{\varepsilon}$: error (no observable)

4.1.1) Estimación de los parámetros

Función Predictora: $\hat{y} = b_0 + b_1 \cdot x$

$$b_1 = \frac{\sum (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sum (x_i - \bar{x})^2} \quad b_0 = \bar{y} - b_1 \cdot \bar{x}$$

Otra fórmula más sencilla (aunque aumenta los errores de redondeo):

$$r^2 = \frac{\sum x_i \cdot y_i - \sum x_i \sum y_i / n}{\sum x_i^2 - (\sum x_i)^2 / n} \cdot \frac{\sum y_i^2 - (\sum y_i)^2 / n}{\sum y_i^2 - (\sum y_i)^2 / n}$$

4.1.2) Coeficientes de Determinación y de Correlación

$$SC_{TOTAL} = SC_{RESIDUAL} + SC_{REGRESION}$$

$$\text{Suma de Cuadrados Residual } Q = \sum (y_i - \hat{y}_i)^2 = \sum (y_i - b_0 - b_1 \cdot x_i)^2$$

$$Q = \sum y_i^2 - b_0 \sum y_i - b_1 \sum x_i \cdot y_i$$

$$\text{Coeficiente de Determinación: } R^2 = 1 - \frac{Q}{\sum (y_i - \bar{y})^2}$$

$$\text{Coeficiente de Correlación: } R = \frac{\sum x_i \cdot y_i - n \cdot \bar{x} \cdot \bar{y}}{\sqrt{(\sum x_i^2 - n \cdot \bar{x}^2)(\sum y_i^2 - n \cdot \bar{y}^2)}}$$

4.1.3) Estimación de la varianza residual

$$s^2 = \frac{Q}{n-2}$$

4.1.4) Inferencia sobre β_1

$$\text{Estadístico } t_v = \frac{b_1 - \beta_1}{\hat{D}(b_1)} \quad \text{con} \quad v = n-2 \quad \hat{D}^2(b_1) = \frac{s^2}{\sum x_i^2 - n \cdot \bar{x}^2}$$

4.1.5) Inferencia sobre $E \tilde{y} / x_0 = \beta_0 + \beta_1 \cdot x_0$ (para Intervalos de confianza)

$$\text{Estimador: } \tilde{y} / x_0 = b_0 + b_1 \cdot x_0 \quad (\text{el punto de la recta para } x_0)$$

$$\text{Estadístico: } t_v = \frac{(b_0 + b_1 x_0) - (\beta_0 + \beta_1 \cdot x_0)}{s_{\tilde{y}/x_0}}$$

$$\text{donde} \quad s_{\tilde{y}/x_0}^2 = \left(\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum x_i^2 - n \bar{x}^2} \right) \cdot s^2$$

$$v = n - 2$$

La inferencia sobre β_0 (ordenada al origen) es un caso particular, basta usar las fórmulas anteriores con $x_0=0$

4.1.6) Inferencia sobre $\hat{y}/x_0 = \beta_0 + \beta_1 \cdot x_0 + \tilde{\varepsilon}$ (para Intervalos de predicción)

Por ser una variable aleatoria se la predice o pronostica

Predictor: $\hat{y}/x_0 = b_0 + b_1 \cdot x_0$

Estadístico: $t_v = \frac{(b_0 + b_1 x_0) - (\beta_0 + \beta_1 x_0 + \tilde{\varepsilon})}{s_{\hat{y}/x_0 - \tilde{y}/x_0}}$

con $s_{\hat{y}/x_0 - \tilde{y}/x_0}^2 = \left(1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum x_i^2 - n\bar{x}} \right) \cdot s^2$
 $v = n - 2$

4.1.7) Regresión con intercepto conocido

Modelo: $\tilde{z}_i = \tilde{y}_i - \beta_0 = \beta_1 x_i + \tilde{\varepsilon}$

La ecuación predictora es $\hat{z} = b_1 x$

Coefficiente de regresión: $b_1 = \frac{\sum x_i \cdot z_i}{\sum x_i^2}$

Estimación de la varianza residual: $s^2 = \frac{Q}{n-1}$

grados de libertad $v = n - 1$

La suma de cuadrados de los residuos $Q = \sum (z_i - b_1 \cdot x_i)^2 = \sum z_i^2 - \frac{(\sum x_i \cdot z_i)^2}{\sum x_i^2}$

Coefficiente de correlación: $R = \sqrt{1 - \frac{Q}{\sum z_i^2}} = \frac{\sum x_i \cdot z_i}{\sqrt{\sum x_i^2 \cdot \sum z_i^2}}$

Varianza del estimador b_1 : $\hat{D}^2(b_1) = \frac{s^2}{\sum x_i^2}$

Dado un valor x_0 de \tilde{x} , la varianza de \hat{z}_0 es: $\hat{D}^2(\hat{z}_0) = s^2 \cdot \frac{x_0^2}{\sum x_i^2}$

4.2) Regresión Múltiple

Siendo:

$$\tilde{Y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \quad X = \begin{bmatrix} 1 & x_{11} & x_{21} & \dots & x_{k1} \\ 1 & x_{12} & x_{22} & \dots & x_{k2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{1n} & x_{2n} & \dots & x_{kn} \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} \quad \tilde{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

$n \times 1$

$n \times p$

$p \times 1$

$n \times 1$

HOJAS DE FÓRMULAS

$$p = k + 1$$

$$\text{Modelo: } \tilde{Y} = X \cdot \beta + \tilde{\varepsilon}$$

Cantidad de variables k

Esta función toma en el dato X el valor $\tilde{y}_i = \beta_0 + \beta_1 \cdot x_{1i} + \beta_2 \cdot x_{2i} + \dots + \beta_n \cdot x_{ni} + \tilde{\varepsilon}_i$

La ecuación predictora es $\hat{Y}_0 = x_0 \cdot b$

4.2.2) Coeficientes de Determinación y de Correlación

$$SC_{TOTAL} = SC_{RESIDUAL} + SC_{REGRESION} = Q + SC_{REGRESION}$$

$$\text{Coeficiente de Determinación: } R^2 = \frac{SC_{REGRESION}}{SC_{TOTAL}} = 1 - \frac{Q}{\sum (y_i - \bar{y})^2}$$

Coeficiente de Determinación Ajustado :

$$R^2 = 1 - \left(\frac{n-1}{n-p} \right) \cdot \frac{Q}{\sum y_i^2} = 1 - (1 - R^2) \left(\frac{n-1}{n-p} \right)$$

4.2.3) Desvío Std. residual

$$s_{RES} = \sqrt{\frac{SC_{RESIDUAL}}{n-p}}$$

$$\text{Estadístico: } \chi^2_v = \frac{n-p}{\sigma^2} \cdot s^2 \quad \text{con } v = n-p$$

4.1.4) Inferencia sobre β

Matriz de covarianza de los estimadores $\|\text{cov}(b_i, b_j)\| = \sigma^2 \cdot (X' \cdot X)^{-1}$, se designa con c_{ij} a; elemento ubicado en la fila i y la columna j de la matriz $(X' \cdot X)^{-1}$

$$\text{Estadístico } t_v = \frac{b_i - \beta_i}{\hat{D}(b_i)} \quad \text{con}$$

4.1.5) Intervalo de confianza

$$\text{Estadístico: } t_v = \frac{x'_o \cdot b - x'_o \cdot \beta}{s \cdot \sqrt{x'_o \cdot (X' \cdot X)^{-1} \cdot x_o}} \quad \text{con } v = n-p$$

4.1.6) Intervalo de Predicción

$$\text{Estadístico: } t_v = \frac{x'_o \cdot b - (x_o \cdot \beta + \tilde{\varepsilon})}{s \cdot \sqrt{1 + x'_o \cdot (X' \cdot X)^{-1} \cdot x_o}} \quad \text{con } v = n-p$$