

# ESTADISTICA 1 (REPASO)

## DEFINICIONES

- **Experimento** = Procedimiento que genera datos
- **Experimento Aleatorio** = Genera distintos resultados así se repita con los mismas condiciones
- **Espacio Muestral** =  $(S)$ , conjunto de todos los posibles resultados
- **Evento** =  $(A_1, A_2, A_3, \dots)$  Subconjunto del espacio muestral  $(S)$
- **Evento nulo** = Subconjunto sin ningún elemento  $(\emptyset)$

Definiendo  $(S)$  y los  $(A_1, A_2, A_3)$  se aplica toda la teoría de conjuntos

## TIPOS DE EVENTOS $(A_n)$

1. **Mutualmente excluyentes**  $A \cap B = \emptyset$  "Union = 0"
2. **Exhaustivos**  $A \cup B = S$  "Intersección"
3. **Unión de eventos**  $A \cup B = \{x \in S / x \in A \vee x \in B\}$
4. **Intersección de eventos**  $A \cap B = \{x \in S / x \in A \wedge x \in B\}$
5. **Complemento**  $A', A'', A^c$

## PROPIEDADES DE LOS EVENTOS

1.  $A \cup \emptyset = A$
2.  $A \cap \emptyset = \emptyset$
3.  $A \cup A' = S$
4.  $A \cap A' = \emptyset$
5.  $S' = \emptyset$
6.  $\emptyset' = S$
7.  $A'' = A$
8.  $(A \cap B)' = A' \cup B'$
9.  $(A \cup B)' = A' \cap B'$

## PROBABILIDAD

$P(A) = \frac{\# \text{ de cosas favorables}}{\# \text{ de cosas posibles}}$

$P(A) = \frac{\# \text{ de elementos de } A}{\# \text{ elementos de } S}$

## FUNCION DE PROBABILIDAD $P(A)$ (AXIOMAS)

Una función  $P: S \rightarrow \mathbb{R}$ , se llama  $P(A)$  si cumple:

- I)  $P(A) \geq 0 \quad \forall A \in S$
- II)  $P(S) = 1$
- III) a) Eventos mutuamente excluyentes finitos

$$P\left(\bigcup_{i=1}^k A_i\right)$$

$$\sum_{i=1}^k P(A_i) = P(A_1) + P(A_2) + \dots + P(A_k)$$

- b) eventos mutuamente excluyentes infinitos

$$P\left(\bigcup_{i=1}^{\infty} A_i\right)$$

$$\sum_{i=1}^{\infty} P(A_i)$$

## PROPIEDADES $P(A)$ (TEORAMA)

- I)  $P(\emptyset) = 0$
- II)  $P(A') = 1 - P(A)$
- III)  $0 \leq P(A) \leq 1$
- IV)  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$
- V) Si  $A \subseteq B$  entonces  $P(A) \leq P(B)$
- VI)  $P(A' \cup B) = P(A \cap B)' = 1 - P(A \cap B)$
- VII)  $P(A \cup B \cup C) = P(A) + P(B) + P(C) - P(A \cap B) - P(A \cap C) - P(B \cap C) + P(A \cap B \cap C)$

## PROBABILIDAD CONDICIONAL

Probabilidad condicional de A dado B se denota  $P(A|B)$

$P(A|B) = \frac{P(A \cap B)}{P(B)} ; P(B) > 0$

$P(B|A) = \frac{P(A \cap B)}{P(A)} ; P(A) > 0$

De lo anterior podemos deducir

$$P(A|B) \cdot P(B) = P(A \cap B)$$

$$P(B|A) \cdot P(A) = P(A \cap B)$$

### TEOREMA DE PROBABILIDAD TOTAL

$A_1, A_2, A_3, \dots, A_n$

- Eventos disjuntos  $A_1, A_2, \dots, A_n$  (mutuamente excluyentes)
- Exhaustivos ( $A_1 \cup A_2 \cup A_3 \dots = S$ )

$$P(B) = \sum_{i=1}^n P(B|A_i) \cdot P(A_i)$$

### TEOREMA DE BAYES

$A_1, A_2, A_3, \dots, A_n$

- Eventos disjuntos
- Exhaustivos

$$P(A_j|B) = \frac{P(A_j) \cdot P(B|A_j)}{\sum_{i=1}^n P(A_i) \cdot P(B|A_i)}$$

### INDEPENDENCIA ENTRE EVENTOS

Son eventos independientes si se cumple cualquiera de los siguientes proposiciones:

- I)  $P(A|B) = P(A)$
- II)  $P(B|A) = P(B)$
- III)  $P(A \cap B) = P(A) \cdot P(B)$

### VARIABLES ALEATORIAS (V.A.)

Es una función que asigna a cada posible resultado  $w$  en el espacio muestral  $S$  un único número real  $X(w)$

### V.A. DISCRETAS (V.A.D.)

Conjunto de valores que toma la variable es finito o numerable (conteos)

#### 1. Distribución de Probabilidad o función de masa de probabilidad (F.M.P)

$$\sum_i P(x_i) = 1$$

$$P(x_1) + P(x_2) + P(x_3) + \dots + P(x_n) = 1$$

#### 2. Función de distribución acumulada (F.d.a)

$$F(x) = P(X \leq x) = \sum_{x' \leq x} P(x')$$

- Fda siempre posee saltos en los puntos correspondientes a valores de la V.A. y la magnitud del salto es igual a la probabilidad F.M.P en dicho punto

#### Proposición

$$P(a \leq X \leq b) = F(b) - F(a^-)$$

$$F(a^-) = \lim_{x \rightarrow a^-} F(x)$$

### V.A. CONTINUAS (V.A.C.)

Es un intervalo o unión de intervalos reales (mediciones)

#### 1. Función de densidad de probabilidad (F.d.P)

$$P(a \leq X \leq b) = \int_a^b f(x) dx$$

$$\int_{-\infty}^{\infty} f(x) dx = \text{Área total bajo la curva} = 1 = \text{Probabilidad total}$$

#### 2. Función de distribución Acumulada

$$F(x) = P(X \leq x) = \int_{-\infty}^x f(w) dw$$

#### Proposiciones

- $P(X > a) = 1 - F(a)$
- $P(a \leq X \leq b) = F(b) - F(a)$
- $F'(x) = dF(x)/dx = f(x)$

#### Valor esperado de un V.A.

$$E[X] = \begin{cases} \sum_i x \cdot P(x) & \text{Discreta} \\ \int_{-\infty}^{\infty} x \cdot f(x) & \text{Continua} \end{cases}$$

Proposiciones

- $E[a] = a$
- $E[ax+b] = aE[X] + b$
- Si  $g(x)$  es una función de  $x$ , entonces

$$E[g(x)] = \sum g(x) P(x) \quad \text{V.A.D}$$

$$= \int_{-\infty}^{\infty} g(x) f(x) dx \quad \text{V.A.C}$$

VARIANZA  $\sigma^2$

$$\text{Var}[X] = E[X^2] - E[X]^2$$

- $\text{Var}[a] = 0$
- $\text{Var}[ax+b] = a^2 \text{Var}[X]$

DESVIACION ESTANDAR  $\sigma$

Es la raíz cuadrada de la varianza

$$\sigma = \sqrt{\text{Var}[X]}$$

TECNICAS DE CONTEO

↳ conteo de resultados

1. Regla multiplicativa

Secuencia de pasos de un mismo proceso

En una manufactura se produce una pieza con 3 operaciones cada operación tiene ciertas herramientas

- Maquinado = 3 herramientas
- Polido = 4 herramientas
- Pintado = 3 herramientas

¿Cuántas rotas distintas son posibles para hacer una pieza?

$$3 \times 4 \times 3 = 36$$

2. Permutaciones

↳ Variación del orden de los elementos

$$nPr$$

Proposiciones

- Para todos los elementos

$$nPr = n!$$

- Con condiciones

$$nPr = \frac{n!}{(n-r)!}$$

- Cuando se permiten repeticiones

$$nPr = n^r$$

- Si cada elemento (evento) es de un tipo distinto

$$P_{n_1, n_2, \dots}^n = \frac{n!}{n_1! n_2! \dots}$$

Juan, Carlos, Ana y Milena esperan el la parada del bus. ¿de cuántas maneras se pueden filar? Si solo hay dos puestes ¿de cuántas maneras se pueden organizar en los dos puestes?

$$- 4! = 24$$

$$- 4P_2 = 4! / (4-2)! = 12$$

3. Combinación

↳ Se tiene en cuenta el orden

$$nC_r = \binom{n}{r} = \frac{n!}{r! (n-r)!}$$

ENSAYO BERNOULLI VAD

$$X \sim \text{Ber}(p)$$

P: Probabilidad del evento

El ensayo de bernoulli se caracteriza por tener dos resultados

$$\text{EXITO} = p$$

$$\text{FRACASO} = 1 - p$$

## DISTRIBUCION BINOMIAL VAD

$$X \sim \text{bin}(n, p)$$

$n$ : # ensayos

$p$ : Probabilidad de cada ensayo

$$\binom{n}{x} p^x (1-p)^{n-x}$$

Recordemos que para que un experimento sea llamado binomial debe cumplir:

1. Costa de  $n$  pruebas idénticas e independientes
2. Cada prueba tiene dos posibles resultados: Éxito o fracaso
3. La probabilidad de éxito es constante en las  $n$  pruebas y se denota  $p$
4. La VA de interés es  $X$ : # éxitos en los  $n$  ensayos

Media

$$E[X] = n \cdot p$$

Varianza

$$\text{Var}[X] = n \cdot p \cdot (1-p)$$

## DISTRIBUCION HIPERGEOMETRICA VAD

$$X \sim \text{hiper}(n, M, N)$$

$n$ : Tamaño de la muestra

$M$ : Éxitos dentro de la muestra

$N$ : Población total

$$P(X=x) = \frac{\binom{M}{x} \binom{N-M}{n-x}}{\binom{N}{n}} = \frac{\text{Casos favorables}}{\text{Casos posibles}}$$

Recordemos las condiciones de una distribución hipergeométrica:

1. Población de  $N$  elementos
2. Hay  $M$  éxitos y  $N-M$  fallos
3. Cualquier muestra de  $n$  elementos es seleccionada al azar, sin reposar y con  $p$  constante

Media

$$E[X] = n \cdot \frac{M}{N}$$

$$p = \frac{M}{N} = \text{Proporcion de éxito}$$

$$E[X] = n \cdot p$$

Varianza

$$\text{Var}[X] = \frac{(N-n)}{N-1} \cdot n \cdot \frac{M}{N} \cdot \left(1 - \frac{M}{N}\right)$$

$$\text{Var}[X] = \frac{(N-n)}{N-1} \cdot E[X] \cdot \left(1 - \frac{M}{N}\right)$$

$$q = 1 - p = \text{Proporcion de fracaso}$$

$$\text{Var}[X] = \frac{(N-n)}{N-1} \cdot E[X] \cdot q$$

## APROXIMACION BINOMIAL DE LA HIPERGEOMETRICA

Si  $\frac{(N-n)}{(N-1)} \approx 1$  entonces

$$\frac{\binom{M}{x} \binom{N-M}{n-x}}{\binom{N}{n}} \approx \binom{n}{x} p^x (1-p)^{n-x}$$

Donde  $p = \frac{M}{N}$  = Proporción de éxito

De la misma manera se puede hacer aproximación binomial cuando

$$n < 5\% \cdot N$$

## DISTRIBUCION DE POISSON VAD

$$X \sim P_{\text{ois}}(\lambda) \quad \frac{e^{-\lambda} \lambda^x}{x!}$$

$\lambda$  = # promedio de ocurrencia por unidad de tiempo o espacio

$$E[X] = \lambda = \text{Var}[X]$$

La f.m.p. =  $F(a) = P(X=a)$

La f.d.a. =  $F(a) = P(X \leq a)$

Recordemos que para que un experimento tenga distribución de Poisson debe cumplir

- $X$  = # Ocurrencias en el intervalo real
- Resultados en intervalos reales: tiempo, espacio
- En cada unidad establecida, el número de eventos que ocurren es independiente de los que ocurren en otras unidades
- La probabilidad en cada subintervalo es despreciable
- La probabilidad es proporcional al

intervalo.

## APROXIMACION POISSON DE LA BINOMIAL

Sea  $X \sim \text{bin}(n, p)$  y

$$\begin{aligned} n &\geq 100 \\ p &< 0,10 \\ np &\leq 10 \end{aligned}$$

Entonces

$$\binom{n}{x} p^x (1-p)^{n-x} \approx \frac{e^{-\lambda} \lambda^x}{x!}$$

Donde  $\lambda = n \cdot p$

## DISTRIBUCION UNIFORME VAC

$$X \sim U(a, b)$$

$(0, b)$  = Intervalo

Función de densidad de probabilidad (f.d.p.)

$$f(x) = \begin{cases} \frac{1}{b-a} & ; a \leq x \leq b \\ 0 & ; \text{en otros casos} \end{cases}$$

$$F(a|b) = P(a < X < b)$$

cuando  $X$  pertenecerá a cualquier subintervalo de la longitud total

Función de distribución acumulada f.d.a.

$$F(x) = \begin{cases} 0 & ; \text{si } x < a \\ \frac{x-a}{b-a} & ; a \leq x \leq b \\ 1 & ; \text{si } x > b \end{cases}$$

$$\int_{-\infty}^x f(v) dv$$

$$E[X] = \frac{a+b}{2} \quad VC[X] = \frac{(b-a)^2}{12}$$

Recordemos que

$$VC[X] = E[X^2] - E[X]^2$$

### DISTRIBUCION NORMAL VAC

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

- $\mu$ : Media, Mediana, Moda = localización
- $\sigma^2$ : Varianza = Escala
- $\sigma$ : Desviación estándar

F.d.P.

$$f(x) = \frac{e^{-\frac{(x-\mu)^2}{2\sigma^2}}}{\sqrt{2\pi} \sigma}; \quad \begin{matrix} -\infty < x < \infty \\ \mu \in \mathbb{R} \\ \sigma > 0 \end{matrix}$$

Recordemos que una distribución normal cumple:

- La distribución normal tiene forma de campana.
- El área de la curva entre  $(-\infty, \infty)$  es igual a 1.
- La normal es simétrica respecto a  $\mu$ , es decir que el área bajo la curva en  $[\mu, \infty)$  es igual a 1/2

- Distribución Normal Estándar (Estandarización)

$$\begin{matrix} \mu=0 \\ \sigma=1 \end{matrix} \Rightarrow \begin{matrix} Z \sim N(0,1) \\ X \sim N(\mu, \sigma^2) \end{matrix}$$

F.d.a. (Dada en general para la distribución Normal a partir de la estándar)

A partir de un cambio de variable donde

$$Z = \frac{X - \mu}{\sigma}; \quad \text{Donde } \sigma^2 \text{ es igual a } \sigma \text{ ya que son } = 1$$

$$dz = \frac{1}{\sigma}$$

Tenemos que:

$$P(x_1 < X < x_2) = \int_{x_1}^{x_2} \frac{e^{-\frac{(x-\mu)^2}{2\sigma^2}}}{\sqrt{2\pi} \sigma} dx$$

$$P(z_1 < Z < z_2) = \int_{z_1}^{z_2} \frac{e^{-(z^2/2)}}{\sqrt{2\pi}} dz$$

Donde:

$$z_1 = \frac{x_1 - \mu}{\sigma} \quad z_2 = \frac{x_2 - \mu}{\sigma}$$

Concluimos que:

$$P(x_1 < X < x_2) = P(z_1 < Z < z_2)$$

Donde:

$$\Phi(z) = P(Z < z) = \int_{-\infty}^z \frac{e^{-(z^2/2)}}{\sqrt{2\pi}} dz$$


Entonces

$$P(z_1 < Z < z_2) = \Phi(z_2) - \Phi(z_1)$$


scribiendo que

$$\Phi(z) = \begin{cases} \frac{1}{2} + \sum_{n=0}^{\infty} \frac{(-1)^n z^{2n+1}}{\sqrt{2\pi} (2n+1) 2^n n!}; & z \geq 0 \\ \frac{1}{2} - \sum_{n=0}^{\infty} \frac{(-1)^n z^{2n+1}}{\sqrt{2\pi} (2n+1) 2^n n!}; & z < 0 \end{cases}$$

Para la tabla encontraremos tablas que resomen todo el procedimiento que nos permite hallar las áreas que necesitamos



Nota<sub>1</sub>: Cuando  $\sigma^2$  se hace mas grande la curva se achata



Nota<sub>2</sub> =  $P(Z > z_\alpha) = \alpha$

Para uso practico de la tabla de Probabilidades es bueno tener en cuenta

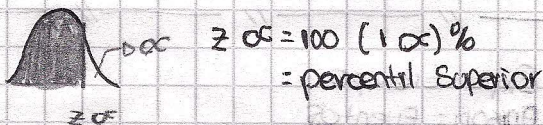
• Si  $a < 0$ ,  $\Phi(a) = 1 - \Phi(-a)$   
por simetria

•  $Z = \frac{X - \mu}{\sigma}$  (Estandarizacion)

• Cuando tenemos una distribucion Normal no estandarizada

\*  $P(a \leq X \leq b) = \Phi\left(\frac{b - \mu}{\sigma}\right) - \Phi\left(\frac{a - \mu}{\sigma}\right)$

\*  $P(X \leq b) = \Phi\left(\frac{b - \mu}{\sigma}\right)$




Area =  $\Phi(z) = P$

~~$\sigma$~~   $\cdot$   ~~$n\sigma$~~   $+ \mu = \mu, \sigma$

Normalizaciones estandar

$P(|X - \mu| \leq n\sigma) = P\left(\frac{|X - \mu|}{\sigma} \leq n\right)$



$= P\left(-n < \frac{X - \mu}{\sigma} < n\right)$

APROXIMACION NORMAL DE LA BINOMIAL

Sea  $X \sim \text{bin}(n, p)$

$n p \geq 10$   
 $n(1-p) \geq 10$

Entonces

$P(X \leq x) = P\left(X \leq x - \frac{1}{2}\right)$

$\approx P \approx \frac{x - \frac{1}{2} - np}{\sqrt{np(1-p)}}$

Donde

$\frac{1}{2}$  = Factor de correccion  
 $np = E[X]$   
 $np(1-p) = \text{Var}[X]$

DISTRIBUCION EXPONENCIAL

$X \sim \text{Exp}(\lambda)$

Es un caso especial de la distribucion gamma con  $k=1$

$\lambda > 0$        $B = 1/\lambda$


Funcion de densidad de probabilidad (f.d.p)

$f(x) = \begin{cases} \lambda e^{-\lambda x}, & x > 0 \\ 0, & \text{otro caso} \end{cases}$

Funcion de distribucion acumulada (F.d.a)

$$F(x) = \begin{cases} 1 - e^{-\lambda x}, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

$$E[X] = \frac{1}{\lambda} = \beta \quad \text{Var}[X] = \frac{1}{\lambda^2}$$



RELACION DISTRIBUCION EXP Y PROCESO DE POISSON

Sea  $X \sim \text{Pois}(\lambda)$  y

$T$  = Variable aleatoria que representa el tiempo (t) entre ocurrencias de proceso Poisson

Entonces

$$T \sim \text{Exp}(\lambda)$$

Donde

$\lambda$  = # Promedio de ocurrencias por unidad de tiempo (t/h)

- Propiedad de carencia de memoria

$$P(X < t_0 + t_1 | X \geq t_0) = P(X < t_1)$$

# como nuevo

DISTRIBUCION LOGNORMAL VAC

Si la variable aleatoria  $Y = \ln(X)$  tiene una distribucion normal con media  $\mu$  y desviacion estandar  $\sigma$  entonces  $X$  tiene una distribucion Lognormal

Funcion de densidad de probabilidad (F.d.P)

$$f(x) = \frac{1}{x \sigma \sqrt{2\pi}} e^{-\frac{(\ln(x) - \mu)^2}{2\sigma^2}}; x > 0$$

Funcion de distribucion acumulada (F.d.a)


$$F(x) = P(X \leq x) = \Phi\left(\frac{\ln(x) - \mu}{\sigma}\right); \forall x > 0$$

La funcion de distribucion acumulada ( $\Phi$ ) proviene de la distribucion normal estandar (Tabla)

$$E[X] = e^{\mu + \frac{\sigma^2}{2}}; \text{Var}[X] = e^{2\mu + \sigma^2} (e^{\sigma^2} - 1)$$

Donde  $\mu$  y  $\sigma^2$  son la media y la Varianza de  $\ln(X)$

La mediana es el percentil 50 y se relaciona con la media con  $\Phi(0) = 0,5$ ; por lo que  $\ln(\tilde{u}) = 0$  y Mediana ( $\tilde{u}$ ) =  $e^0$



$$\sigma_1^2 > \sigma_2^2 > \sigma_3^2$$

Exp: tiempo  
Poisson: Eventos  
Binomial = Exito - Fracaso



## DISTRIBUCIONES BIVARIADAS

Involucran dos variables aleatorias  
 $X$  y  $Y$

### VARIABLES ALEATORIAS DISCRETAS (VAD)

Función de masa de probabilidad (f.m.p.) conjunta

$$P(x, y) = P(X=x, Y=y), \forall (x, y) \in A \subseteq \mathbb{R}^2$$

- Propiedades

$$1. P(x, y) \geq 0 \quad \forall (x, y) \in A$$

$$2. \sum_x \sum_y P(x, y) = \sum_{(x, y) \in A} P(x, y) = 1$$

$$3. \text{Si } A \subseteq \mathbb{R}^2 \Rightarrow P((X, Y) \in A) = \sum_{(x, y) \in A} P(x, y)$$

Recordar

$$P(X=x) = \sum_y P(x, y)$$

$$P(Y=y) = \sum_x P(x, y)$$

$X$	1	2	3	4	...
$Y_1$					
$Y_2$					
$Y_3$					
$Y_4$					
...					

Dependiendo de las probabilidades se puede presentar simetría

### VARIABLES ALEATORIAS CONTINUAS (VAC)

Función de distribución acumulada (f.d.a.) conjunta

$$F(x, y) = P(X \leq x, Y \leq y), \forall (x, y) \in \mathbb{R}^2$$

$F$  es continua en  $\mathbb{R}^2$ , si existe una función  $f: \mathbb{R}^2 \rightarrow \mathbb{R}^+ \cup \{0\}$  tal que:

$$\frac{\partial^2 F(x, y)}{\partial x \partial y} = f(x, y)$$

$\forall (x, y)$  donde exista  $\frac{\partial^2 F}{\partial x \partial y}$  entonces

La función de densidad de probabilidad (f.d.p.) conjunta es  $f$

$$f(x, y)$$

- Propiedades

$$1. F(x, y) = \int_{-\infty}^x \int_{-\infty}^y f(t, s) ds dt$$

$$2. \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) dx dy = 1$$

$$3. \text{Si } B \subseteq \mathbb{R}^2 \Rightarrow$$

$$P((X, Y) \in B) = \iint_B f(x, y) dx dy$$

### DISTRIBUCIONES MARGINALES Y CONDICIONALES

#### VARIABLES ALEATORIAS DISCRETAS (VAD)

• Distribución Marginal

$$P_X(x) = \sum_y P(x, y)$$

$$P_Y(y) = \sum_x P(x, y)$$

$$x_1 \quad x_2 \quad \dots \quad x_i \quad \dots$$

$$y_1 \quad \dots \quad y_j \quad \dots \quad * = P_Y(y)$$

$$y_2$$

$$y_3$$

$$\vdots$$

$$y_j$$

$$\vdots$$

$$\vdots$$

$$\vdots$$

$$P_X(x)$$

• Distribucion Condicional "Y dado X=x"

$$P_{Y|X}(y) = \frac{P(x,y)}{P_X(x)}, \text{ si } P_X(x) > 0$$

Sea  $g(X,Y)$  una funcion de  $X$  e  $Y = X \cdot Y$ .  $g: A \subseteq \mathbb{R}^2 \rightarrow \mathbb{R}$  Entoces

$$E[g(X,Y)] = \sum_x \sum_y g(x,y) P(x,y)$$

Si  $g(X,Y) = X$  se obtiene  $E[X]$

Si  $g(X,Y) = Y$  se obtiene  $E[Y]$

Si  $g(X,Y) = (X - \mu_x)^2$  se obtiene  $\text{Var} = \sigma_x^2$

Sea  $X$  e  $Y$  Variables aleatorias diveras que son Estadisticamente Independientes (EI), Si:

$$P(X,Y) = P_X(x) \cdot P_Y(y)$$

VARIABLES ALEATORIAS CONTINUAS (VAC)

• Distribucion Marginal

$$F_X(x) = \int_{-\infty}^{\infty} F(x,y) dy$$

$$F_Y(y) = \int_{-\infty}^{\infty} F(x,y) dx$$

• Distribucion Condicional de "Y dado X=x"

$$f_{Y|X}(y) = \frac{F(x,y)}{F_X(x)}, \text{ si } f_X(x) > 0$$

Por deducion

$$F(x,y) = F_X(x) \cdot f_{Y|X}(y) = f_Y(y) F_{X|Y}(x)$$

Sean  $X$  e  $Y$  Variables aleatorias diveras que son estadisticamente independientes (EI) Si:

$$f(x,y) = F_X(x) \cdot f_Y(y), \forall (x,y) \in A$$

Si existe un par  $(x,y)$  para el cual la igualdad no es cierta, diveras que  $X$  e  $Y$  son estadisticamente Dependientes (ED)

Sea  $g(X,Y)$  una funcion de  $X$  e  $Y = X \cdot Y$ .  $g: A \subseteq \mathbb{R}^2 \rightarrow \mathbb{R}$  entoces


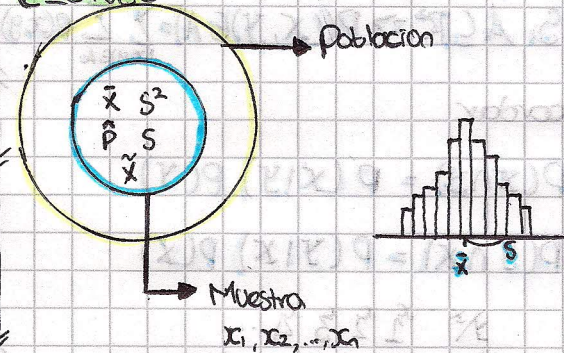
$$E[g(X,Y)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x,y) f(x,y) dx dy$$

Si  $g(X,Y) = X$  se obtiene  $E[X]$

Si  $g(X,Y) = Y$  se obtiene  $E[Y]$

Si  $g(X,Y) = (X - \mu_x)^2$  se obtiene  $\text{Var} = \sigma_x^2$

ESTADISTICOS Y SUS DISTRIBUCIONES



Estadistico Parametro

En general estimamos 3 parametros dependiendo del caso

- Una Proporción (P)
- Un Promedio (M)
- Una Varianza ( $\sigma^2$ )

Un estadistico es la estimacion de un parametro a partir de una Muestra

• Muestra Aleatoria (M.A.)

Una M.A. de tamaño  $n$ , es un conjunto de VA EI e idénticamente distribuidas. Si  $X_1, \dots, X_n$  es una M.A. entonces

I.  $F(X_1, \dots, X_n) = \prod_{i=1}^n F_{X_i}(x_i)$

II.  $f_{X_i}(x_i) = f(x_i); \forall i=1, \dots, n$

• Estimaciones (Estimables mesgadas)

$\mu \Rightarrow \bar{x} = \frac{1}{n} \sum x_i$

$\sigma^2 \Rightarrow s^2 = \frac{1}{n-1} \sum (x_i - \bar{x})^2$

$P \Rightarrow \frac{x}{n}, X \sim \text{bin}(n, P)$

DISTRIBUCION DE LA MEDIA MUESTRAL

Sea  $X_1, \dots, X_n$  una muestra aleatoria (M.A.) de una distribución con media  $\mu$  y varianza  $\sigma^2$  y

Sea  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ . Entonces

$E[\bar{X}] = E\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \frac{1}{n} \sum_{i=1}^n E[X_i]$

$E[\bar{X}] = \frac{1}{n} \sum_{i=1}^n \mu = \frac{n\mu}{n} = \mu$

$E[\bar{X}] = \mu$

$\text{Var}[\bar{X}] = \text{Var}\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \frac{1}{n^2} \sum_{i=1}^n \text{Var}[X_i]$

$\text{Var}[\bar{X}] = \frac{\sigma^2}{n}$

Sea  $T_0 = \sum_{i=1}^n X_i$ . Entonces

$E[T_0] = n\mu; \text{Var}[T_0] = n\sigma^2$

$T_0$ : Total de la muestra

Proposición 1

Sean  $X$  y  $Y$  VA EI con  $\sim N(\mu, \sigma^2)$  cada una con sus parámetros

$X \sim N(\mu_x, \sigma_x^2)$

$Y \sim N(\mu_y, \sigma_y^2)$

Y sea  $Z$  VA

$Z = aX \pm bY$

Entonces

$\mu_z = a\mu_x \pm b\mu_y$

$\sigma_z^2 = a^2\sigma_x^2 + b^2\sigma_y^2$

Proposición 2

$X_1, X_2, \dots, X_n$  una muestra aleatoria de una  $\sim N(\mu, \sigma^2)$  Entonces

$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$  y

$T_0 \sim N(n\mu, n\sigma^2)$

Entonces estandarizamos

$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0,1)$  y  $\frac{T_0 - n\mu}{\sigma\sqrt{n}} \sim N(0,1)$

TEOREMA DEL LIMITE CENTRAL (TLC)

Suponga que  $X_1, X_2, \dots, X_n$  es una M.A. de una población con cualquier distribución, media  $\mu$  y varianza  $\sigma^2$ . Sea  $\bar{x}$  la media muestral (que depende de  $n$ ) entonces cuando  $n \rightarrow +\infty$ , la distribución muestral de

$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$  es aproximadamente normal estandar. Escribimos

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \stackrel{\text{Aprox}}{\sim} n(0,1) \quad n \rightarrow \infty$$

De igual manera con  $T_0$

$$\frac{T_0 - n\mu}{\sigma\sqrt{n}} \stackrel{\text{Aprox}}{\sim} n(0,1) \quad n \rightarrow \infty$$

- Entre mayor sea  $n$ , mayor es la aproximación
- Regla empírica: Si  $n > 30$ , se puede utilizar (T.L.C)
- Si la distribución de la muestra es simétrica y continua, los tamaños muestrales relativamente pequeños permiten obtener buenas aproximaciones.
- Si la distribución es discreta, se requiere de tamaños muestrales grandes

Así

$$P(\bar{X} \leq a) = P\left(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq \frac{a - \mu}{\sigma/\sqrt{n}}\right)$$

$$\approx P\left(Z \leq \frac{a - \mu}{\sigma/\sqrt{n}}\right)$$

Si  $\sigma^2$  es desconocida y  $n$  grande se puede reemplazar  $\sigma^2$  por  $S^2$ . Así:

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \stackrel{\text{Aprox}}{\sim} n(0,1) \quad n \rightarrow \infty$$

$$\frac{T_0 - n\mu}{S\sqrt{n}} \stackrel{\text{Aprox}}{\sim} n(0,1) \quad n \rightarrow \infty$$

### ESTIMACIÓN PUNTUAL

Parametro                      Estimador

$\theta$

$\hat{\theta}$

- Media
- Mediana
- Media recortada
- Media Min-Max

Hay dos tipos de estimadores en los M.A.

1. Puntuales (único valor)
2. Por intervalos

• Propiedades deseables de un estimador


Un estimador puntual  $\hat{\theta}$  de  $\theta$  es INESESADO si

$$E[\hat{\theta}] = \theta \quad ; \quad B = 0$$

Si  $\hat{\theta}$  es sesgado, se define como:

$$B = E[\hat{\theta}] - \theta$$

$$B = \text{Sesgo}$$



$E[\hat{\theta}_A] = \theta$   
Insesgado


$E[\hat{\theta}_B] \neq \theta$   
Sesgado

Entre dos estimadores insesgados para  $\theta$ , se prefiere aquel con menor Varianza

$$\text{Var}[\hat{\theta}_1] < \text{Var}[\hat{\theta}_2]$$

Entonces  $\hat{\theta}_1$  es Mejor estimador de  $\theta$  que  $\hat{\theta}_2$ .

El Mejor estimador ( $\hat{\theta}_1$ ) insesgado que tiene menor varianza es llamado: Estimador Insesgado de Mínima Varianza (MIVUE)



**- Error Cuadrado Medio (ECM)**

Medida para comprobar el mejor estimador, se elige aquel con menor ECM

$$ECM[\hat{\theta}] = E[(\hat{\theta} - \theta)^2] = \text{Var}[\hat{\theta}] + \beta^2$$

↳ cuadrado de los errores

Para los estimadores insesgados  $\beta=0$ , por lo cual el mejor estimador sera el de menor varianza

**• Teorema**

Sea  $X_1, \dots, X_n$  una muestra aleatoria de una  $n \sim (M, \sigma^2)$ . Entonces,  $\bar{X}$  es el MVUE para  $M$ .

**• Error Estandar**

Si  $\hat{\theta}$  es un estimador de  $\theta$ , el error estandar sera su desviacion estandar

$$\sqrt{\text{Var}[\hat{\theta}]}$$

Para una M.A de una poblacion con media  $M$  e varianza  $\sigma^2$ , se tiene que un estimador insesgado para  $M$  es  $\bar{X}$ , cuya varianza es  $\sigma^2/n$ . Asi el error estandar de  $\bar{X}$  esta dado por

$$\sigma_{\bar{X}} = \sigma / \sqrt{n}$$

Si  $\sigma$  se desconoce se puede usar la desviacion estandar muestral

$$S_{\bar{X}} = S / \sqrt{n}$$

**Recordemos**

- $E[a] = a$
- $E[ax+b] = a E[X] + b$
- $\text{Var}[ax+b] = a^2 \text{var}[X]$
- $\text{Var}[X] = E[X^2] - (E[X])^2$

Para distribuciones bivariadas en VAID usamos Sumatorias y en VAC Integrales.

$$E[X] = \int_A x f(x,y) dA$$

$$E[X^2] = \int_A x^2 f(x,y) dA$$

$$E[XY] = \int_A xy f(x,y) dA$$

**- Covarianza**

$$\text{Cov}[X,Y] = E[XY] - E[X]E[Y]$$

$$* \text{Cov}[ax+b, cy+d] = ac \text{cov}[X,Y]$$

**- Correlacion**

$$\text{Corr}[X,Y] = \frac{\text{Cov}[X,Y]}{\sigma_x \cdot \sigma_y}$$

$$* \text{Corr}[ax+b, cy+d] = \text{Corr}[X,Y]$$

Si dos muestras estan relacionadas  $\text{Cov}[X,Y] \neq 0$  entonces

$$\text{Var}[ax+by] = a^2 \text{var}[X] + b^2 \text{var}[Y] + 2ab \text{cov}[X,Y]$$

Si  $\text{Cov}[X,Y] = 0$  entonces

$$\text{Var}[ax+by] = a^2 \text{var}[X] + b^2 \text{var}[Y]$$

\* Los muestras aleatorias nunca estan relacionados,  $\text{Cov}[X,Y] = 0$

# MAXIMA VEROSIMILITUD

Es un método para estimar parámetros desconocidos, sean un # finito de parámetros.

Sea  $X_1, \dots, X_n$  una muestra aleatoria de una distribución  $F$  que depende de uno(s) parámetro(s)  $\theta, \Delta$ . La función de verosimilitud se define como

$$L(\theta, \Delta) = \prod_{i=1}^n f(x_i; \theta, \Delta)$$

EMV = Estimador de máxima Verosimilitud de  $\theta$  o  $\Delta$

EMV, es aquel que maximiza a  $L(\theta, \Delta)$ ; en general se maximiza con mayor facilidad el logaritmo natural de  $L(\theta)$ .

• ¿cómo se calculan los EMV?

- Hallamos la función de verosimilitud  $L(\theta, \Delta)$
- Hallamos el  $\ln[L(\theta, \Delta)] = \ln L(\theta, \Delta)$
- Hallamos las derivadas parciales respecto a los parámetros  $(\frac{\partial}{\partial \theta})$  y  $(\frac{\partial}{\partial \Delta})$  e igualamos a cero

$\hat{\theta}$  = EMV de  $\theta$   
 $\hat{\Delta}$  = EMV de  $\Delta$

Nota = \* Los EMV no son siempre insesgados  
 \* Los EMV no tienen siempre varianzas mínimas

Para verificar que efectivamente son EMV utilizamos la segunda derivada

$$\begin{bmatrix} \frac{\partial^2}{\partial \theta^2} & \frac{\partial^2}{\partial \theta \partial \Delta} \\ \frac{\partial^2}{\partial \theta \partial \Delta} & \frac{\partial^2}{\partial \Delta^2} \end{bmatrix}$$

Si la matriz es negativa se cumple

que  $\frac{\partial}{\partial \theta}$  y  $\frac{\partial}{\partial \Delta}$  son EMV

Para un solo parámetro verificamos que la segunda derivada tenga signo negativo (-)

En los EMV si  $n$  es grande es aproximadamente insesgado y MUVE.

- Principio de Invarianza

Si  $\hat{\theta}$  es EMV de  $\theta$ , entonces  $h(\hat{\theta})$  es el estimador máximo verosímil de  $h(\theta)$

Sea  $f(\theta) = \frac{x}{\theta} e^{-x^2/2\theta}$   
 y sea  $\hat{\theta}_{EMV} = \frac{\sum x_i^2}{2n}$

Entonces si tenemos que la mediana de  $f(\theta) \Rightarrow \sqrt{2 \ln(2) \cdot \theta}$

Entonces un EMV de la mediana será:

$$\sqrt{2 \ln(2) \cdot \hat{\theta}} = \sqrt{2 \ln(2) \cdot \frac{\sum x_i^2}{n}}$$

- EMV para la Varianza de una distribución normal

$$S = \sqrt{\frac{\sum (x_i - \bar{x})^2}{n}}$$

Por principio de invarianza

$$S^2 = \frac{\sum (x_i - \bar{x})^2}{n}$$

Nota = Recordando que  $\hat{\sigma}^2$  es un estimador insesgado de  $\sigma^2$

$$\hat{\sigma}^2 = \frac{\sum (x_i - \bar{x})^2}{n-1}$$

Entonces


$$\frac{s^2}{\sigma^2} = \frac{n}{n-1}$$

cuando  $n \rightarrow \infty$  este coeficiente se hace 1

↳ tiene menor varianza que  $\hat{\sigma}^2$

- Intervalo de confianza "Donde está el parámetro"
- Intervalo de predicción "Valor de un nuevo evento"
- Límite de tolerancia "Donde están la mayoría de datos"

### INTERVALOS DE CONFIANZA



$$\Phi(z_{\alpha}) = 1 - \alpha$$

$\alpha$  = Nivel de significancia  
Niveles de confianza  
(1 -  $\alpha$ ) 100%  
95%, 98%, 99%

#### - Intervalos Unilaterales Aleatorios

- $P(L < Z_{\infty}) = 1 - \alpha$
- $P(Z_{-\infty} < U) = 1 - \alpha$

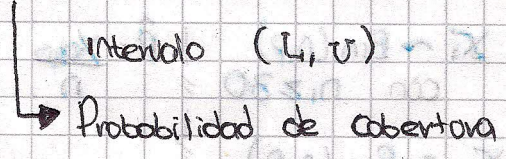
Para una muestra particular tenemos

- $(L, +\infty)$
- $(-\infty, U)$


En los intervalos unilaterales no tenemos precisión

#### - Intervalos Bilaterales Aleatorios


$$P(L < \theta < U) = 1 - \alpha$$



#### \* Intervalo Asimétrico



#### \* Intervalo Simétrico



$$P\left(\left|\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}\right| \leq z_{\alpha/2}\right)$$

$$P(-z_{\alpha/2} \leq Z \leq z_{\alpha/2})$$

$$P\left(-z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}} \leq \bar{X} - \mu \leq z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}}\right)$$

$$P\left(\bar{X} - z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}}\right)$$

Intervalo

$$\left(\bar{X} - z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}}\right)$$

#### - Interpretación

\* Con un nivel de confianza  $100(1 - \alpha)\%$  el verdadero valor del parámetro estaba entre  $L$  y  $U$

\* De 100 intervalos de confianza, el 95% de ellos tendrá el valor del parámetro

#### - Precisión

Longitud = Límite Superior - Límite inferior  
=  $U - L$

#### Teorema

$$n \geq \left(\frac{z_{\alpha/2} \cdot \sigma}{e}\right)^2$$

A mayor confiabilidad menor precisión

\* Tamaño de muestra que permite estimar  $\mu$

\* Máximo error que se comete al estimar a  $\mu$  con un nivel de confianza  $100(1 - \alpha)\%$

\* Con un nivel de confianza de 100(1-α)% el valor de la precisión no excedera cierta cota E

$$S^2 = \frac{\sum x_i^2 - n\bar{x}^2}{n-1}$$

Para calculadora

Boostrapp

$$\frac{\bar{x} - \mu}{S/\sqrt{n}} \stackrel{\text{Aprox}}{\sim} N(0,1)$$

$$(\hat{\theta} - P_{97.5}, \hat{\theta} - P_{2.5})$$

- Se generan M muestras de tamaño n

- Con cada M se calcula  $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_M$

$$\hat{\theta} = \frac{1}{M} \sum \hat{\theta}_i$$

- Calcule  $\hat{\theta}_1 - \hat{\theta}, \dots, \hat{\theta}_M - \hat{\theta}$

- Halle el percentil 97,5 y 2,5 de los M valores

### INTERVALOS DE CONFIANZA DE POBLACIONES NORMALES

- Si la varianza  $\sigma^2$  es conocida

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

- Si la varianza  $\sigma^2$  es desconocida

$$\bar{x} \pm t_{\alpha/2, v} \cdot \frac{s}{\sqrt{n}}$$

Donde  $v = n - 1$

↳ Grados de libertad

### INTERVALOS DE CONFIANZA DE POBLACIONES NO NORMALES

Se debe cumplir la regla empirica.  $n \geq 30$

- Si la varianza  $\sigma^2$  es conocida

$$\bar{x} \pm z_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}} \quad \text{Aproximado por TLC}$$

- Si la varianza  $\sigma^2$  es desconocida

$$\bar{x} \pm z_{\alpha/2} \cdot \frac{s}{\sqrt{n}} \quad \text{Aproximado por TLC}$$

### INTERVALOS DE CONFIANZA PARA LA DIFERENCIA DE 2 PROPORCIONES P1 - P2 DE DOS POBLACIONES INDEPENDIENTES

$$\text{Si } X_1 \sim \text{Bin}(n_1, p_1) \quad \hat{p} = \frac{X_{obs}}{n_1}$$

$$\text{y } X_2 \sim \text{Bin}(n_2, p_2) \quad \text{con } n_2 \geq 30$$

Entonces:

$$\hat{p}_1 - \hat{p}_2 \pm z_{\alpha/2} \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}}$$

### INTERVALO DE CONFIANZA PARA UNA PROPORCION P DE UNA POBLACION

$$\text{Si } X \sim \text{Bin}(n, p) \quad n \geq 30$$

tenemos que

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

$$\hat{p} = \frac{X_{obs}}{n}$$

Ademas para la precision tenemos

$$n \geq \frac{1}{4} \cdot \left( \frac{z_{\alpha/2}}{E} \right)^2$$



Si el intervalo contiene al cero se dice que  $\mu_1$  y  $\mu_2$  no son significativamente distintos. Es decir  $\mu_1 \approx \mu_2$

**INTERVALOS DE CONFIANZA PARA LA DIFERENCIA DE DOS MEDIAS  $\mu_1 - \mu_2$  DE DOS POBLACIONES NORMALES**

- Si  $\sigma_1^2$  y  $\sigma_2^2$  Conocidas

$$\bar{X}_1 - \bar{X}_2 \pm Z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}$$

- Si  $\sigma_1^2$  y  $\sigma_2^2$  Desconocidas

- Si  $\sigma_1^2 = \sigma_2^2$

$$\bar{X}_1 - \bar{X}_2 \pm t_{\alpha/2, v} \cdot SP \cdot \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

$$v = (n_1 + n_2) - 2$$

$$SP = \sqrt{\frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}}$$

- Si  $\sigma_1^2 \neq \sigma_2^2$

$$\bar{X}_1 - \bar{X}_2 \pm t_{\alpha/2, v} \cdot \sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}$$

$$v = \frac{\left(\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}\right)^2}{\frac{\left(\frac{S_1^2}{n_1}\right)^2}{n_1 - 1} + \frac{\left(\frac{S_2^2}{n_2}\right)^2}{n_2 - 1}} \quad \text{Aproximado}$$

**INTERVALOS DE CONFIANZA PARA LA DIFERENCIA DE MEDIAS  $\mu_1 - \mu_2$  DE DOS POBLACIONES NO NORMALES**

Se debe cumplir la regla empírica  $n_1 \geq 30$  y  $n_2 \geq 30$

- Si  $\sigma_1^2$  y  $\sigma_2^2$  Conocidas

Aproximado

$$\bar{X}_1 - \bar{X}_2 \pm Z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}$$

- Si  $\sigma_1^2$  y  $\sigma_2^2$  Desconocidas

Aproximado

$$\bar{X}_1 - \bar{X}_2 \pm Z_{\alpha/2} \sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}$$

Si el intervalo contiene al cero los promedios son muy similares

Si el intervalo está a la derecha de cero  $\mu_1 > \mu_2$

Si el intervalo está a la izquierda de cero  $\mu_2 > \mu_1$

**TEST DE HIPOTESIS**

Afirmación sobre un valor de un parámetro de una distribución

En cualquier problema  $H_0$  (Prueba de hipótesis) hay dos hipótesis contradictorias que se contrastan entre sí

- Hipótesis nula ( $H_0$ )  
Desigualdad no estricta o igualdad ( $\leq, \geq, =$ )

- Hipótesis alternativa ( $H_a$ )  
Desigualdad estricta o diferencia ( $<, >, \neq$ )

Objetivo: Decidir rechazar  $H_0$  o no rechazar  $H_0$

**PROCEDIMIENTO  $H_0$**

- Definir estadístico de prueba ( $Z_c, T_c, F_c, X_c$ )
- Definir región de rechazo

- Hallar P-value

## TIPOS DE ERRORES

- Error tipo (I)

$P(\text{Rechazar } H_0 \mid H_0 \text{ cierta})$

$\alpha = P(\text{Error tipo I})$

↳ Nivel de significancia  
Máxima probabilidad de error

- Error tipo (II)

$P(\text{Aceptar } H_0 \mid H_0 \text{ falsa})$

$\beta = P(\text{Error tipo II})$

$1 - \beta = \text{Potencia de la prueba}$

### • Interpretaciones

-  $\alpha$  (Significancia)

Cada vez que rechazamos  $H_0$  y  $H_0$  es verdadera, nos podemos estar equivocando el  $P(\text{Error tipo I})$  de las veces

-  $\beta$  (Potencia)

Cada vez que no rechazamos  $H_0$  y  $H_0$  es falsa, nos podemos estar equivocando aproximadamente el  $P(\text{Error tipo II})$  de las veces

## DECISIÓN CON P-VALEJE.

El valor -P de una  $P_h$  es la probabilidad calculada, suponiendo que  $H_0$  es verdadera, de que el estadístico de prueba tome un valor obtenido

- Se rechaza  $H_0$  si  $P\text{-value} < \alpha$

- Aumentar tamaño de muestra si  $P\text{-value} = \alpha$

- No se rechaza  $H_0$  si  $P\text{-value} > \alpha$

## $P_h$ Para $\mu$

$H_0: \mu = \mu_0$

$\mu > \mu_0$  (1)

$\mu < \mu_0$  (2)

$\mu \neq \mu_0$  (3)

### • Poblaciones Normales

- Si la varianza  $\sigma^2$  es conocida

$$Z_c = \frac{\bar{X} - \mu_0}{\sigma / \sqrt{n}} \sim N(0,1)$$

- Si la varianza  $\sigma^2$  es desconocida

$$T_c = \frac{\bar{X} - \mu_0}{S / \sqrt{n}} \sim t_{n-1}$$

### • Poblaciones No Normales

▪ Se debe cumplir la regla empírica  $n \geq 30$

- Si la varianza  $\sigma^2$  es conocida

$$Z_c = \frac{\bar{X} - \mu_0}{\sigma / \sqrt{n}} \sim N(0,1)$$

- Si la varianza  $\sigma^2$  es desconocida

$$Z_c = \frac{\bar{X} - \mu_0}{S / \sqrt{n}} \sim N(0,1)$$

Región de rechazo y P-Value

(1) RR:  $Z_c > Z_\alpha$

RR:  $T_c > t_{\alpha, n-1}$

$P(Z > Z_c)$

$P(T > T_c)$

(2) RR:  $Z_c < -Z_{\alpha}$   $P(Z < Z_c)$   
 RR:  $T_c < -t_{\alpha, n-1}$   $P(T < T_c)$

- Si  $\sigma_1^2$  y  $\sigma_2^2$  conocidas

(3) RR:  $|Z_c| > Z_{\alpha/2}$   $2P(Z > |Z_c|)$   
 RR:  $|T_c| > t_{\alpha/2, n-1}$   $2P(T > |T_c|)$

$$Z_c = \frac{\bar{x}_1 - \bar{x}_2 - \delta_0}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \sim n(0,1)$$

Aproximadamente

Ph para  $\mu_1 - \mu_2$

$H_0: \mu_1 - \mu_2 = \delta_0$

$\mu_1 - \mu_2 > \delta_0$  (1)

$\mu_1 - \mu_2 < \delta_0$  (2)

$\mu_1 - \mu_2 \neq \delta_0$  (3)

- Si  $\sigma_1^2$  y  $\sigma_2^2$  desconocidas

$$Z_c = \frac{\bar{x}_1 - \bar{x}_2 - \delta_0}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}}$$

Aproximadamente

• Poblaciones Normales

- Si  $\sigma_1^2$  y  $\sigma_2^2$  conocidas

$$Z_c = \frac{\bar{x}_1 - \bar{x}_2 - \delta_0}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \sim n(0,1)$$

Region de rechazo y P-value

(1) RR:  $Z_c > Z_{\alpha}$   $P(Z > Z_c)$   
 RR:  $T_c > t_{\alpha, g1}$   $P(T > T_c)$

(2) RR:  $Z_c < -Z_{\alpha}$   $P(Z < Z_c)$   
 RR:  $T_c < -t_{\alpha, g1}$   $P(T < T_c)$

- Si  $\sigma_1^2$  y  $\sigma_2^2$  desconocidas e iguales (Prueba F)

$$T_c = \frac{\bar{x}_1 - \bar{x}_2 - \delta_0}{SP \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \sim t_{n_1+n_2-2}$$

$$SP = \sqrt{\frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2}}$$

(3) RR:  $|Z_c| > Z_{\alpha/2}$   $2P(Z > |Z_c|)$   
 RR:  $|T_c| > t_{\alpha/2, g1}$   $2P(T > |T_c|)$

g1 = grados de libertad  
 $T_{g1} = T$

- Si  $\sigma_1^2$  y  $\sigma_2^2$  desconocidos y diferentes (Prueba F)

$$Z_c = \frac{\bar{x}_1 - \bar{x}_2 - \delta_0}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \sim tv$$

$$v \Rightarrow \frac{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}{\left(\frac{S_1^2}{n_1}\right)^2 + \left(\frac{S_2^2}{n_2}\right)^2}$$

Ph para P

$H_0: P = P_0$

$H_a: P > P_0$  (1)  $\hat{P} = \frac{x}{n}$   
 $P < P_0$  (2)  
 $P \neq P_0$  (3)

$$Z_c = \frac{\hat{P} - P_0}{\sqrt{\frac{P_0(1-P_0)}{n}}} \sim n(0,1)$$

Aproximadamente

Region de rechazo y P-value

(1) RR:  $Z_c > Z_{\alpha}$   $P(Z > Z_c)$   
 (2) RR:  $Z_c < -Z_{\alpha}$   $P(Z < Z_c)$   
 (3) RR:  $|Z_c| > Z_{\alpha/2}$   $2P(Z > |Z_c|)$

• Poblaciones No Normales

Se debe cumplir la regla Empirico  $n_1, n_2 \geq 30$

Ph para  $\mu_1 - \mu_2$

$H_0: \mu_1 - \mu_2 = d_0$

- $\mu_1 - \mu_2 > d_0$  (1)
- $\mu_1 - \mu_2 < d_0$  (2)
- $\mu_1 - \mu_2 \neq d_0$  (3)

$\hat{P} = \frac{\sum x}{n}$

Para  $z_c$  hay dos opciones

$z_c = \frac{\hat{p}_1 - \hat{p}_2 - d_0}{\sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}}}$

$z_c = \frac{\hat{p}_1 - \hat{p}_2 - d_0}{\sqrt{P(1-P) \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}}$  Cuando  $d_0 = 0$

Donde

$P = \frac{\sum x_1 + \sum x_2}{n_1 + n_2}$

Region de rechazo y P-value

- |                                |                 |
|--------------------------------|-----------------|
| (1) RR: $z_c > z_{\alpha}$     | $P(z > z_c)$    |
| (2) RR: $z_c < -z_{\alpha}$    | $P(z < z_c)$    |
| (3) RR: $ z_c  > z_{\alpha/2}$ | $2P(z >  z_c )$ |

Ph para  $\sigma_1^2 / \sigma_2^2$

Razon de varianzas o homocedasticidad

$H_0: \sigma_1^2 = \sigma_2^2$

- $\sigma_1^2 > \sigma_2^2$  (1)
- $\sigma_1^2 < \sigma_2^2$  (2)
- $\sigma_1^2 \neq \sigma_2^2$  (3)

$F_c = \frac{S_1^2}{S_2^2} \sim F_{n_1-1, n_2-1}$

Region de rechazo y P-Value

(1) RR:  $F_c > F_{1-\alpha}(n_1-1, n_2-1)$

$P(F > F_c)$

(2) RR:  $F_c < \frac{1}{F_{1-\alpha}(n_2-1, n_1-1)}$

$P(F < \frac{1}{F_{1-\alpha}(n_2-1, n_1-1)})$


(3) RR:  $F_c < \frac{1}{F_{1-\alpha/2}(n_2-1, n_1-1)}$

$F_c > F_{\alpha/2}(n_1-1, n_2-1)$

$\min \{ P(F_{(n_1, n_2)} > F_c), P(F_{(n_1, n_2)} < F_c) \}$

$F_c < 1, P(F_{(n_1, n_2)}) + P(F_{(n_2, n_1)} > \frac{1}{F_c})$

Nota:  $F_{\alpha/2}(n_1-1, n_2-1) = \frac{1}{F_{1-\alpha/2}(n_2-1, n_1-1)}$



$\alpha = P(F > F_{\alpha}(v_1, v_2))$

Ph Bondad de ajuste

Se utiliza la prueba Chi Cuadrado en VAD

Generalmente se utiliza en un experimento Multinomial, con K posibles Categorías

Se utiliza para comprobar ciertas distribuciones o/y las proporciones que corresponden a cierto experimento

Cuando queremos verificar proporciones utilizamos

$H_0$ : Todas las probabilidades  $P_i$  son iguales a los propuestos  $P_i^0$

$\forall P_i = P_i^0$

$H_a$ : Al menos una de las probabilidades  $P_i$  es distinta a la propuesta.

$\exists_i$  tal que  $P_i \neq P_i^0$

Cuando queremos verificar cierta distribución con su parámetro

$H_0$ : Los datos corresponden a la distribución con ese parámetro

$X \sim \text{Pois}(k)$   
 $\dots \dots X \sim$  Cierta dist<sup>n</sup>  
 $\dots \dots$

$H_a$ : Los datos no corresponden a la distribución con ese parámetro

$X \not\sim \text{Pois}(k)$   
 $\dots \dots X \not\sim$  Cierta dist<sup>n</sup>  
 $\dots \dots$

$$\chi^2_c = \sum_{i=1}^k \frac{(O_i - e_i)^2}{e_i}$$

$O_i$ : Frecuencias observadas  
 $e_i$ : Frecuencias esperadas =  $nP_i$


Para aplicar el test Chi-Cuadrado se debe cumplir la regla empírica

$nP_i \geq 5$   
 $e_i \geq 5$

De no cumplirse utilizamos categorías

P-Value

$$P(\chi^2_{(k-r-1)} > \chi^2_c)$$
  
 $k = \text{Clases}$   
 $r = \text{Parámetros estimados}$



Para concluir las pruebas de hipótesis utilizamos la hipótesis ~~...~~ ( $H_a$ ) de tal manera que al:

Rechazar  $H_0$

Basados en el criterio de ... (1) ... se rechaza  $H_0$ , es decir que hay evidencia muestral suficiente para sugerir que ... (Ha cierta) (2) ... con una significancia de  $\alpha\%$

No Rechazar  $H_0$

Basados en el criterio de ... (1) ... no se rechaza  $H_0$ , es decir que no hay evidencia muestral suficiente para sugerir que ... (Ha cierta) (2) ... con una significancia de  $\alpha\%$

(1) decisión del valor P la región de rechazo

(2)  $>, <, \neq$  Parámetro (s)