

Definiciones, Teoremas y Propiedades de Probabilidades y Estadística

1. Espacios y Probabilidades

- **Def.:** Definimos al conjunto \mathcal{S} el **Espacio Muestral** como el que contiene todos los posibles resultados de un experimento. A cada subconjunto del espacio muestral lo llamamos **Evento**. Definimos el **Espacio de Eventos** como el conjunto \mathcal{F} que contiene todos los posibles eventos.
- **Prop.:** Sea \mathcal{S} un espacio muestral numerable $\implies \mathcal{F} = \mathcal{P}(\mathcal{S})$.
- **Def.:** Definimos la **Probabilidad** como $\mathbb{P} : \mathcal{F} \rightarrow [0, 1] / (\mathbb{P}(\mathcal{S}) = 1) \wedge (\{A_n\}, n \in [1, N] \subseteq \mathbb{N} / A_i \cap A_j = \emptyset \forall i, j \implies \mathbb{P}\left(\bigcup_{n=1}^N A_n\right) = \sum_{n=1}^N \mathbb{P}(A_n))$.
- **Def.:** Sea \mathcal{S} un espacio muestral / $\mathbb{P}(A) = \mathbb{P}(B) \forall A, B \in \mathcal{S}$ lo llamamos un **Espacio Muestral Equiprobable**.
- **Prop.:** Sean A y B dos eventos llamamos la **Probabilidad Condicional** de A dado B a la probabilidad de que el evento A suceda dado que sucede el evento B y vale que $\mathbb{P}(A|B) = \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)}$.
- **Def.:** Sean A y B dos eventos los llamamos **Independientes** $\iff \mathbb{P}(A \cap B) = \mathbb{P}(A)\mathbb{P}(B)$. Notamos $A \perp B$.
- **Prop.:** Sean A y B dos eventos, son independientes $\iff \mathbb{P}(A|B) = \mathbb{P}(A)$.
- **Fórmula de Probabilidad Total:** Sea $I = \{B_i\}, i \in [1, N] \subseteq \mathbb{N}$ una partición del espacio muestral y A un evento $\implies \mathbb{P}(A) = \sum_{i=1}^N \mathbb{P}(A|B_i)\mathbb{P}(B_i)$.
- **Fórmula de Bayes:** Sea $I = \{B_i\}, i \in [1, N] \subseteq \mathbb{N}$ una partición del espacio muestral y A un evento $\implies \mathbb{P}(B_i|A) = \frac{\mathbb{P}(A|B_i)\mathbb{P}(B_i)}{\sum_{j=1}^N \mathbb{P}(A|B_j)\mathbb{P}(B_j)}$.
- **Def.:** Sea $\{A_i\}, i \in [1, N] \subseteq \mathbb{N}$ un conjunto de eventos lo llamamos una **Familia de Eventos Independientes** $\iff \mathbb{P}\left(\bigcap_{i=1}^N A_i\right) = \prod_{i=1}^N \mathbb{P}(A_i)$.

2. Variables Aleatorias Discretas

- **Def.:** Definimos una **Variable Aleatoria Discreta** como una función $X : \mathcal{S} \rightarrow \mathbb{N}$.
- **Def.:** Definimos la **Función de Probabilidad** o **Distribución de Probabilidad** como la función $P : \mathbb{N} \rightarrow [0, 1] / \mathbb{P}(x) = \mathbb{P}(X(w) = x) \forall w \in \mathcal{S}$.
- **Def.:** Sea X una variable aleatoria y P la distribución de probabilidad de X entonces notamos $X \sim P$.
- **Def.:** Sea X una variable aleatoria definimos la **Probabilidad Acumulada** como $\mathbb{P}(X \leq x) = \sum_{X=i}^x \mathbb{P}(X = i)$.
- **Def.:** Definimos la **Esperanza** como la función $E : \mathcal{S} \rightarrow \mathbb{N} / E(X) = \sum_X x\mathbb{P}(X = x)$.

- **Prop.:** Sean X e Y variables aleatorias $(g : \mathbb{N} \rightarrow \mathbb{N}) \wedge (y = g(x)) \implies E(Y) = \sum_X g(x) \mathbb{P}(X = x)$
- **Def.:** Sea X una variable aleatoria llamamos **Varianza** a la función $V(X) = E((X - E(X))^2)$.
- **Def.:** Sea X una variable aleatoria llamamos **Desvío Estándar** a la función $\sigma(X) = \sqrt{V(X)}$.
- **Prop.:** Sea X una variable aleatoria $\implies V(X) = E(X^2) - E(X)^2$.
- **Prop.:** Sea X una variable aleatoria y $V_{(X,m)} = \sum_X (x - m)^2 \mathbb{P}(X = x) \implies V(X) \leq V_{(X,m)} \forall m \in \mathbb{R}$.
- **Prop.:** Sean $X \sim \mathcal{G}(p) \implies \mathbb{P}(X > k + l | X > l) = \mathbb{P}(X > k) \forall k, l \in \mathbb{N}$.

3. Variables Aleatorias Continuas

- **Def.:** Llamamos a X una **Variable Aleatoria Continua** si $(X : \mathcal{S} \rightarrow \mathbb{R}) \wedge (\mathbb{P}(X \in A) = \int_A f(x) dx)$. Llamamos a f la **Distribución de Probabilidad** de X . Esta distribución debe cumplir que $(f : \mathbb{R} \rightarrow \mathbb{R}) \wedge (f(x) \geq 0 \forall x \in \mathbb{R}) \wedge \left(\int_{-\infty}^{\infty} f(x) dx = 1 \right)$. Definimos también la **Distribución Acumulada** como $F_{(t)} = \int_{-\infty}^t f(x) dx$.
- **Def.:** Sea f una distribución y $p \in [0, 1]$ llamamos **Percentil** de p a $x_p / \int_{-\infty}^{x_p} f(x) dx = p$.
- **Def.:** Sea f una distribución y X una variable aleatoria llamamos **Promedio** de una función $g : \mathbb{R} \rightarrow \mathbb{R}$ a $\langle g \rangle = \int_{-\infty}^{\infty} g(x) f(x) dx$.
- Sea f una distribución llamamos **Mediana** al percentil de $\frac{1}{2}$.
- **Prop.:** Sea X una variable aleatoria con distribución f , $X \geq 0 \implies \langle X \rangle = \int_0^{\infty} (1 - F_{(x)}) dx$, $F_{(x)} = \int_{-\infty}^x f(u) du$.
- **Lema:** Sea $X \sim \mathcal{N}(\mu, \sigma^2) \iff Z = \frac{X - \mu}{\sigma} \sim \mathcal{N}(0, 1)$.
- **Def.:** Sea $X \sim \mathcal{N}(0, 1) \implies \Phi_{(z)} = \mathbb{P}(X \leq z)$.
- **Prop.:** Sea $X \sim \mathcal{N}(\mu, \sigma^2) \implies \mathbb{P}(X \leq z) = \Phi_{\left(\frac{z - \mu}{\sigma}\right)}$.
- **Prop.:** Sea $X \sim \mathcal{E}(\lambda) \implies \mathbb{P}(X > t + s | X > s) = \mathbb{P}(X > t)$.
- **Prop.:** $\lim_{n \rightarrow \infty} \mathcal{G}\left(\frac{\lambda}{n}\right) = \mathcal{E}(\lambda)$.
- **Prop.:** Sean $X_i \sim \mathcal{E}(\lambda) \implies \sum_{i=1}^n X_i \sim \Gamma(n, \lambda)$.
- **Prop.:** Sea $X \sim \Gamma(n, \alpha) \implies \lambda X \sim \Gamma\left(n, \frac{\alpha}{\lambda}\right) \forall \lambda \in \mathbb{R}$.
- **Prop.:** Sean $X_i \sim \mathcal{P}(\lambda_i) \implies \sum_{i=1}^n X_i \sim \mathcal{P}\left(\sum_{i=1}^n \lambda_i\right)$.
- **Def.:** Sean X e Y variables aleatorias son independientes $\iff \langle f(x)g(x) \rangle = \langle f(x) \rangle \langle g(x) \rangle \forall f, g$.
- **Teorema:** Sea X una variable aleatoria acotada, $X \in (a, b)$, $a, b \in \mathbb{R}$, con distribución f_x , sea $g : (a, b) \rightarrow \mathbb{R}$ biyectiva e $Y = g(x) \implies f_{y(y)} = \frac{f_x(g^{-1}(y))}{\left|g'(g^{-1}(y))\right|}$.

4. Vectores Aleatorios

- Def.:** Definimos un **Vector Aleatorio** a un vector $\mathbf{X} : \mathcal{S} \rightarrow \mathbb{R}^N$ con distribución $f : \mathbb{R}^N \rightarrow \mathbb{R} / \int_{\mathcal{S}} f(\mathbf{x}) d\mathbf{x} = 1, f(\mathbf{x}) \geq 0 \forall \mathbf{x}$. Sea $\Xi = \{x_i \in \mathbb{R} / x_i \leq t_i \forall i \in [1, N], \mathbf{t} \in \mathbb{R}^N\}$ definimos la distribución acumulada de \mathbf{X} como $F(\mathbf{t}) = \int_{\Xi} f(\mathbf{x}) d\mathbf{x}$.
- Def.:** Sea \mathbf{X} un vector aleatorio con distribución f definimos la **Distribución Marginal** de una coordenada x_i como $f_{X_i(x_i)} = \int_{\mathbb{R}^{N-1}} f(\mathbf{x}) d\tilde{\mathbf{x}}$, donde $\tilde{\mathbf{x}}$ es el vector con todas las coordenadas de \mathbf{x} menos x_i .
- Prop.:** Sean X e Y variables aleatorias discretas y g y h funciones tal que $\mathbb{P}(X = x, Y = y) = Cg(x)h(y)$ donde $C \in \mathbb{R} \implies X \perp Y, \mathbb{P}(X = x) = \left(\sum_{x'} g(x')\right)^{-1} g(x), \mathbb{P}(Y = y) = \left(\sum_{y'} h(y')\right)^{-1} h(y)$.
- Prop.:** Sean X e Y variables aleatorias con distribuciones f_X y f_Y respectivamente entonces son independientes $\iff f_{(x,y)} = f_{X(x)}f_{Y(y)}$.
- Prop.:** Sea $h : \mathbb{R}^N \rightarrow \mathbb{R}, \mathbf{X}$ un vector aleatorio con distribución $f \implies E(h(\mathbf{X})) = \int_{\mathbb{R}^N} h(\mathbf{x})f(\mathbf{x})d\mathbf{x}$.
- Def.:** Sean X e Y variables aleatorias definimos la **Covarianza** de ambos como $\text{Cov}(X, Y) = E((X - E(X))(Y - E(Y)))$.
- Prop.:** Sean X e Y variables aleatorias, $X \perp Y \implies \text{Cov}(x, y) = 0$.
- Def.:** Sean X e Y variables aleatorias definimos el **Coefficiente de Correlación** entre ambas como $\rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma(X)\sigma(Y)}$.
- Prop.:** Sean X e Y variables aleatorias $\implies f_{X|Y=y(x)} = \frac{f(x,y)}{f_Y(y)}$.
- Teorema:** Sea X una variable aleatoria y $\{A_i\}, i \in [1, n] \subseteq \mathbb{N}$ una partición del espacio muestral $\implies E(X) = \sum_{i=1}^n E(X|A_i)\mathbb{P}(A_i)$.

5. Ley de Grandes Números y Teorema Central del Límite

- Def.:** Sea X una variable aleatoria definimos un **Modelo** de X a un vector \mathbf{X} de variables aleatorias independientes e idénticamente distribuidas (o *iid*) $X_i \sim X \forall i \in [1, n] \subseteq \mathbb{N}$. A algún valor \mathbf{x} del modelo de X lo llamamos una **Muestra** de X
- Def.:** Sea \mathbf{X} modelo de X definimos a la **Media Muestral** de X como $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$. Vale además que $E(\bar{X}) = E(X)$ y $V(\bar{X}) = \frac{V(X)}{n}$.
- Def.:** Sea \mathbf{X} modelo de X definimos a la **Desviación Estándar** como $\sigma_n(\mathbf{X}) = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2}$, y definimos el **Error Estadístico** como $\frac{\sigma_n(\mathbf{X})}{\sqrt{n}}$.
- Desigualdad de Markov:** Sea $X > 0$ una variable aleatoria con esperanza finita y $\epsilon > 0 \implies \mathbb{P}(X > \epsilon) \leq \frac{E(X)}{\epsilon}$.
- Desigualdad de Chebyshev:** Sea X una variable aleatoria con esperanza finita y $\epsilon > 0 \implies \mathbb{P}(|X - E(X)| \geq \epsilon) \leq \frac{V(X)}{\epsilon^2}$.
- Ley de Grandes Números:** Sea X una variable aleatoria y \mathbf{x} un modelo de $X \implies \lim_{n \rightarrow \infty} \mathbb{P}(|X_n - X| > \epsilon) = 0 \forall \epsilon > 0$. En particular, vale que $\lim_{n \rightarrow \infty} \mathbb{P}(|\bar{X} - E(X)| > \epsilon) = 0$.

- **Def.:** Sea X una variable aleatoria llamamos el **Momento** de orden k de X a $m_k = E(X^k) < \infty$. En general se refiere a m_1 como **Posición**, a m_2 como **Dispersión**, a m_3 como **Asimetría** y a m_4 como **Kurtosis**.
- **Def.:** Sea X una variable aleatoria definimos la **Función Generadora de Momentos** de X como $M_X : \mathbb{R} \rightarrow \mathbb{R}$, $M_X(t) = E(e^{tX})$.
- **Teorema:** Sea X una variable aleatoria $\implies m_k = \left. \frac{d^k}{dt^k} M_X(t) \right|_{t=0}$.
- **Teorema de Unicidad:** Sea X una variable aleatoria \implies su función generadora de momentos es única.
- **Teorema:** Sean X_i , $i \in [1, n] \subseteq \mathbb{N}$ variables aleatorias / $X_i \perp X_j \forall i \neq j$, $Y = \sum_{i=1}^n X_i \implies M_{Y(t)} = \prod_{i=1}^n M_{X_i(t)}$.
- **Def.:** Sean $\{X_i\}$, $i \in \mathbb{N}$ una sucesión de variables aleatorias decimos que **Converge en Distribución** a otra variable aleatoria $X \iff \lim_{i \rightarrow \infty} F_{X_i(x)} = F_X(x)$. Notamos $X_i \rightarrow X$.
- **Teorema Central del Límite:** Sean X_i variables aleatorias *iid* con media μ y varianza σ^2 y sea $S_n = \sum_{i=1}^n X_i \implies Z_n = \frac{S_n - n\mu}{\sqrt{n}\sigma} \rightarrow Z$, donde $Z \sim \mathcal{N}(0, 1)$.
- **Teorema:** Sea X una variable aleatoria entonces converge en distribución a alguna otra variable aleatoria \iff hay convergencia de las distribuciones acumuladas \iff existen y convergen las funciones generadoras de momentos.

6. Estadística

- **Def.:** Sea X una variable aleatoria definimos un **Parámetro** de X como una variable que caracteriza la distribución de X . Notamos a la distribución de X como $f(\theta; x)$, donde θ es un parámetro de X .
- **Def.:** Sea \mathbf{X} un modelo de X definimos el **Estimador Puntual** $\hat{\theta}_n$ como una variable aleatoria función del modelo que estima el parámetro de X . Llamamos **Estimación** o **Estimativa** al estimador aplicado a una muestra.
- **Def.:** Sea $\hat{\theta}_n$ un estimador lo llamamos **Consistente** si $\hat{\theta}_n \rightarrow \theta$, donde θ es el parámetro.
- **Def.:** Sea $\hat{\theta}_n$ un estimador y θ el parámetro definimos el **Sesgo** como $b = E(\hat{\theta}_n) - \theta$. Llamamos a un estimador **Insesgado** si no tiene sesgo y **Asintóticamente Insesgado** si $\lim_{n \rightarrow \infty} b = 0$.
- **Def.:** Sea \mathbf{X} un modelo de X definimos al **Momento Muestral** de orden k de \mathbf{X} como $\hat{m}_k = \frac{1}{n} \sum_{i=1}^n X_i^k$.
- **Def.:** Sea θ parámetro de X y $\exists k \in \mathbb{N} / m_k$ sea función inversible de θ entonces se define el **Estimador de Momento** de θ como $\hat{\theta}_n = \hat{m}_k^{-1}$.
- **Def.:** Sea \mathbf{X} una muestra de X con parámetro θ definimos la **Función de Verosimilitud** como $\mathcal{L}(\theta; \mathbf{x}) = \mathbb{P}(\mathbf{X} = \mathbf{x})$. En el caso continuo se define $\mathcal{L}(\theta; \mathbf{x}) = \prod_{i=1}^n f(\theta; x_i)$.
- **Def.:** Sea θ parámetro de X definimos el **Estimador de Máxima Verosimilitud** a $\hat{\theta}_n / \mathcal{L}(\theta; \mathbf{x})$ sea máximo.
- **Def.:** Sea $\hat{\theta}_n$ un estimador de θ llamamos **Error** a $(\hat{\theta}_n - \theta)$, **Error Estándar** a $\sigma(\hat{\theta}_n)$ y **Error Cuadrático Medio** a $\text{ECM}(\hat{\theta}_n) = E((\hat{\theta}_n - \theta)^2)$.
- **Prop.:** Sea $\hat{\theta}_n$ un estimador de $\theta \implies \text{ECM}(\hat{\theta}_n) = b^2(\hat{\theta}_n) + V(\hat{\theta}_n)$.

- **Def.:** Sea \mathbf{X} modelo de X definimos la **Varianza Muestral** como $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$.
- **Prop.:** Sea \mathbf{X} modelo de X entonces, a diferencia de su desviación estándar, la varianza muestral es un estimador insesgado.
- **Lema:** Sea $\hat{\theta}_n$ estimador de θ si es asintóticamente insesgado y $\lim_{n \rightarrow \infty} V(\hat{\theta}_n) = 0 \implies$ es consistente.
- **Def.:** Sea \mathbf{X} modelo de X con parámetro θ llamamos **Intervalo de Confianza** de nivel $1 - \alpha$, donde α es la **Probabilidad de Error**, a un intervalo aleatorio $I / \mathbb{P}(\theta \in I) = 1 - \alpha$ y que es independiente de θ .
- **Prop.:** Sea \mathbf{X} modelo de X con parámetro θ y $T(\theta; \mathbf{X})$ una función inversible cuya distribución no depende de θ la llamamos **Función Pivote** y sean $a, b \in \mathbb{R} / \mathbb{P}(a \leq T \leq b) = 1 - \alpha, \alpha \in [0, 1] \subseteq \mathbb{R} \implies I = [T_{(a)}^{-1}, T_{(b)}^{-1}]$ es un intervalo de confianza de nivel $1 - \alpha$ de θ .
- **Prop.:** Sean $z \sim \mathcal{N}(0, 1), U \sim \chi_n^2 \implies z \sqrt{\frac{n}{U}} \sim t_n$.
- **Prop.:** Sean $X_i \sim \mathcal{N}(\mu, \sigma^2)$ iid $\implies S_n^2 \sim \chi_n^2, S_n^2 \perp \bar{X}, \sqrt{n} \left(\frac{\bar{X} - \mu}{S_n^2} \right) \sim t_{n-1}$.
- **Def.:** Definimos un **Test** como una regla de decisión basada en una variable aleatoria que llamamos **Estadístico** que depende de la muestra y de ciertos parámetros a testear. Estableciendo una **Hipótesis Nula** que va a ser sujeta al test vamos a calcular el estadístico y definir una **Zona de Rechazo**, tal que si el estadístico cae en esta zona entonces se rechazará la hipótesis nula. A esta zona de rechazo la vamos a definir utilizando una **Hipótesis Alternativa** a la hipótesis nula y el **Error de Tipo I**, que es la probabilidad de rechazar la hipótesis nula dado que es verdadera. Llamamos **Error de tipo II** a la probabilidad de no rechazar la hipótesis nula cuando esta es falsa.
- **Def.:** Sea t el estadístico medido usando H_0 la hipótesis nula definimos el **p-Valor** como $p = \mathbb{P}(|T| \geq t | H_0)$. Se puede usar esta cantidad para determinar el resultado de un test rechazando la hipótesis nula si $p > \alpha$, donde α es el error de tipo I.

7. Distribuciones

7.1. Discretas

Nombre	Distribución	E(X)	V(X)	$M_X(t)$
Bernoulli	$\text{Be}(p) = p\delta_{X_1} + (1-p)\delta_{X_0}$ (*)	p	$p(1-p)$	$pe^t + 1 - p$
Geométrica	$\mathcal{G}(p) = p(1-p)^{x-1}$ (*)	$\frac{1}{p}$	$\frac{1-p}{p^2}$	$\frac{pe^t}{1-(1-p)e^t}$
Binomial	$\text{B}(n, p) = \binom{n}{x} p^x (1-p)^{n-x}$ (*)	np	$np(1-p)$	$(pe^t + 1 - p)^n$
Binomial Negativa	$\text{NB}(r, p) = \binom{x-1}{r-1} p^r (1-p)^{x-r}$ (*)	$\frac{r}{p}$	$\frac{r(1-p)}{p^2}$	$\left(\frac{pe^t}{1-(1-p)e^t}\right)^r$
Poisson	$\mathcal{P}(\lambda) = \frac{\lambda^x}{x!} e^{-\lambda}$ (***)	λ	λ	$e^{\lambda(e^t - 1)}$
Hipergeométrica	$\mathcal{H}(N, B, m) = \frac{\binom{B}{x} \binom{N-B}{m-x}}{\binom{N}{m}}$ (**)	$m \frac{B}{N}$	$m \frac{B}{N} \frac{(N-B)}{N} \frac{(N-m)}{(N-1)}$	—
Empírica	$\hat{F}(n) = \frac{1}{n} \sum_{i=1}^n \delta_{X_i X}$ (****)	$\frac{1}{n} \sum_{i=1}^n X_i$	$\frac{1}{n} \sum_{i=1}^n (X_i - E(X))^2$	$\frac{1}{n} \sum_{i=1}^n e^{tX_i}$

Tabla 1: Distribuciones Discretas Usuales

7.2. Continuas

Nombre	Distribución	E(X)	V(X)	$M_X(t)$
Normal	$\mathcal{N}(\mu, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$	μ	σ^2	$e^{\frac{\sigma^2 t^2}{2} + \mu t}$
Uniforme	$\mathcal{U}(a, b) = \frac{1}{b-a} \mathbb{I}_{(a,b)}(x)$	$\frac{a+b}{2}$	$\frac{(b-a)^2}{12}$	$\frac{e^{bt} - e^{at}}{t(b-a)}$
Exponencial	$\mathcal{E}(\lambda) = \lambda e^{-\lambda x} \mathbb{I}_{(0,\infty)}(x)$ (***)	$\frac{1}{\lambda}$	$\frac{1}{\lambda^2}$	$\frac{\lambda}{\lambda-t} \mathbb{I}_{(-\infty, \lambda)}(t)$
Gamma	$\Gamma(\alpha, \lambda) = \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x} \mathbb{I}_{(0,\infty)}(x)$ (***)	$\frac{\alpha}{\lambda}$	$\frac{\alpha}{\lambda^2}$	$\left(\frac{\lambda}{\lambda-t}\right)^\alpha \mathbb{I}_{(-\infty, \lambda)}(t)$
Chi Cuadrado	$\chi_n^2 = \Gamma\left(\frac{n}{2}, \frac{1}{2}\right)$ (***) (****)	n	$2n$	$(1-2t)^{-\frac{n}{2}} \mathbb{I}_{(-\infty, \frac{1}{2})}(t)$
t-Student	$t_n = \frac{\Gamma(\frac{n+1}{2})}{\sqrt{n\pi}\Gamma(\frac{n}{2})} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}$ (***) (****)	$0, n > 1$	$\frac{n}{n-2}, n > 2$	—

Tabla 2: Distribuciones Continuas Usuales

- (*): $p \in (0, 1) \subseteq \mathbb{R}$.
- (**): N total poblacional, B “buenos” en la población y m total de la muestra.
- (***) : $\lambda, \alpha > 0, \lambda, \alpha \in \mathbb{R}, \mathbb{I}$ es la función indicatriz.
- (****): X_i muestra de X, δ_{ij} es la delta de Kronecker.
- (*****) : $n \in \mathbb{N}$ grados de libertad.