

# Curso Machine Learning

Tema 2: Probabilidad y Estadística, conceptos básicos.

Magdalena Lucini, Sebastián Filipigh, Luis Duarte

FaCENA - UNNE - 2023

# Introducción

## Estadística

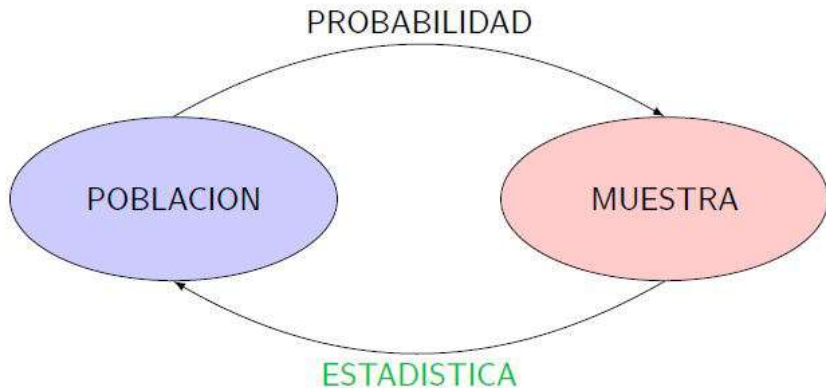
Algunas definiciones:

- ▶ Disciplina científica que se ocupa de la obtención, orden y análisis de un conjunto de datos con el fin de obtener explicaciones y predicciones sobre fenómenos observados.
- ▶ Disciplina que estudia la variabilidad, recolección, organización, análisis, interpretación y presentación de los datos, así como el proceso aleatorio que los genera siguiendo las leyes de la probabilidad
- ▶ Ciencia que se ocupa de la recolección, resumen, análisis, e interpretación de hechos o datos numéricos.

## Algunos objetivos

- ▶ **Extraer conocimiento** a partir de un conjunto de datos, con el fin de **tomar decisiones** en base a la mejor información posible (siempre existe incertidumbre).
- ▶ Obtener información de una **población**, sin necesidad de estudiar todos los elementos que la componen.
- ▶ Sacar conclusiones sobre alguna característica de una **población** en base a una **muestra** respresentativa de la misma

# Introducción



# Introducción

## Estadística Descriptiva:

- ▶ Herramientas para resumir un conjunto de datos (modelados como realizaciones de una variable aleatoria), a través de ciertas medidas numéricas. Representa la información de una manera distinta para facilitar su interpretación, pero no permite realizar predicciones o inferencias
- ▶ Muchos datos (modelados como realizaciones de alguna variable/vector aleatorio): recolectar/resumir/presentar/graficar/analizar.
- ▶ Métodos no supervisados (reducción de dimensionalidad)
- ▶ Facilita interpretación, NO permite realizar predicciones o inferencias.

## Estadística Inferencial

- ▶ Usar datos disponibles para **aprender**, **predecir**, hacer generalizaciones , etc.
- ▶ Estimar, predecir, inferir, pronosticar, ajustar, etc
- ▶ Pruebas de hipótesis, regresión, clasificación, etc.

# Algunos conceptos de Estadística Descriptiva

## Organización y Presentación de resultados

- ▶ Representaciones tabulares (tablas): 1<sup>er</sup> paso en la organización de datos, que se ordenan en filas y columnas para documentar y comunicar la información.
- ▶ Representaciones gráficas (histogramas, gráficos de barras, circulares, etc): brindan un resumen visual de los datos.
- ▶ Medidas descriptivas numéricas (variables cuantitativas): medidas de tendencia central, posición, dispersión, forma.
- ▶ Dependiendo del tipo de datos e información a comunicar se elegirá qué tipo de representación utilizar.

## Ejemplo: Base de datos diabetes gestacional

Base de datos con información de un estudio observacional de factores de riesgo en la presencia de Diabetes Gestacional (DG), llevado a cabo en un grupo de 48 mujeres en el año 2018 en la ciudad de Córdoba, Argentina.

caso_control	Respuesta: Presencia o ausencia de Diab. Gestacional (DG)	0= no tiene DG 1= tiene DG
Edad	Edad en años	
estacivil	Estado civil:	1 casada 2=concubina 3= separada
Pp	Peso pregestacional (Kg)	
Pa	Peso actual (Kg)	
Talla	Estatura (m)	
enpregest	Estado nutricional pregestacional	1= bajo peso 2= peso normal 3= sobrepeso 4= obesidad
Enactual	Estado nutricional actual	1= bajo peso 2= peso normal 3= sobrepeso 4= obesidad
Obrasoc	Obra social	0= no tien 1= si tiene
Estudios	Máximo nivel de estudios alcanzados	1= primario 2= secundario 3= terciario o universitario
Estrsoc	Estrato social	1= bajo 2= medio 3=alto
Actfpre	Actividad física pregestacional	0=NO 1=Si
Antdb	Antecedentes familiares de diabetes	0=NO 1= Si
Fumaud	Estatus de Fumadora previo al embarazo	0=NO 1= Si
Eg	Edad estacional (semanas de gestación)	
comidas_dia	Cantidad de comidas realizadas al día	
Vet	Valor energético total de la dieta (calorías/día)	
Fe	Hierro dietario (mg/día)	
Calico	Calcio dietario (mg/día)	
Cho	Carbohidratos dietarios (g/día)	
beb_azucar	Consumo de bebidas azucaradas (cc/día)	

# Base de datos diabetes gestacional

A	C	D	E	F	G	H	I	J	K	L	M	N	U	P	Q	R	S	T	U	V	W	X	Y
1	caso control	edad	eg	estacivil	pp	pa	talla	IMC_pg	IMC actual	enpregest	enactual	obrasoc	estudios	estrasc	actpre	antdb	fumaud	comidas	vet	fe	calcio	cho	beb_azucar
2	Tiene DG	30	35	casada	70,00	78,00	1,60	27,34	30,47	3	2	1	2	Medio	0	1	0	5	2243,34	16,29	621,92	450,00	98,
3	No tiene DG	31	28	casada	58,50	63,00	1,65	21,49	23,14	2	2	1	3	Alto	1	1	1	4	2449,85	17,83	621,79	223,04	114,29
4	No tiene DG	33	36	casada	55,00	66,00	1,53	23,50	28,19	2	2	1	3	Alto	1	0	0	3	2321,03	16,96	426,21	310,97	228,57
5	Tiene DG	30	28	Concubina	83,00	90,00	1,60	32,42	35,16	4	3	1	3	Bajo	0	1	1	4	5034,36	35,96	1134,84	483,74	914,29
6	No tiene DG	32	35	casada	79,00	86,00	1,60	30,86	33,59	4	3	1	2	Bajo	0	0	1	2	2546,82	19,28	355,20	197,48	500,
7	No tiene DG	31	39	Concubina	61,00	75,00	1,60	23,83	29,30	2	2	1	1	Alto	1	0	0	5	2314,75	13,21	772,41	265,15	342,86
8	Tiene DG	21	38	casada	80,00	88,00	1,65	29,38	32,32	3	3	1	1	Bajo	0	1	0	2	3662,79	26,34	721,94	391,02	320,
9	No tiene DG	23	34	casada	49,00	54,00	1,56	20,13	22,19	2	1	1	2	Bajo	0	1	0	4	2251,56	16,92	594,60	266,94	120,
10	No tiene DG	18	37	casada	49,00	64,00	1,73	16,37	21,38	1	1	1	2	Bajo	1	1	0	3	2106,17	19,77	635,10	235,01	85,71
11	Tiene DG	25	33	casada	60,00	53,00	1,58	24,03	21,23	2	1	1	1	Bajo	0	1	1	4	2540,21	14,23	854,70	304,35	914,
12	No tiene DG	23	37	casada	56,00	65,00	1,55	23,31	27,06	2	2	1	2	Medio	0	1	0	3	3522,14	17,67	1180,48	367,18	400,
13	No tiene DG	26	37	casada	57,00	72,00	1,62	21,72	27,43	2	2	1	2	Medio	0	1	0	4	2082,93	11,17	791,40	242,73	571,43
14	Tiene DG	27	37	casada	91,00	100,00	1,73	30,41	33,41	4	3	1	3	Alto	0	1	0	4	2496,39	24,55	876,59	311,40	875,
15	No tiene DG	29	28	casada	48,00	55,50	1,60	18,75	21,68	2	1	1	2	Medio	1	0	0	5	3575,05	19,56	790,66	368,00	428,57
16	No tiene DG	29	39	casada	55,00	63,00	1,59	21,76	24,92	2	2	1	2	Medio	0	1	0	4	3698,53	14,92	952,02	307,74	668,
17	Tiene DG	24	30	casada	62,00	70,50	1,50	27,56	31,33	3	3	0	2	Bajo	1	1	1	3	2916,38	13,06	978,96	241,45	457,14
18	No tiene DG	26	37	casada	58,00	74,00	1,67	20,80	26,53	2	2	0	3	Alto	0	1	1	4	2994,17	22,68	266,88	301,74	0,
19	No tiene DG	21	38	casada	68,00	80,00	1,60	26,56	31,25	3	2	0	2	Medio	1	1	0	3	3550,62	29,40	937,04	369,79	235,
20	Tiene DG	32	39	casada	68,00	78,00	1,73	22,72	26,06	2	2	1	2	Medio	0	1	1	4	3212,56	24,87	399,52	383,47	800,



# Generalidades

En general, una base de datos es del tipo:

$$\mathbf{x} = \begin{bmatrix} x_1(t_1) & \dots & x_p(t_1) \\ \vdots & \ddots & \vdots \\ x_1(t_n) & \dots & x_p(t_n) \end{bmatrix}$$

- ▶  $x_i$ = variables,  $i = 1 \dots p$  (Cualquier característica susceptibles de tomar distintos estados entre unidades elementales, o que varían dentro de una misma unidad elemental a través del tiempo)
- ▶  $t_j$  = tiempo, observaciones, realizaciones, etc.  $j = 1, \dots, n$   
Es usual agupar los elementos de  $\mathbf{x}$  por
  - ▶ Filas (clustering)
  - ▶ Columnas (correlación)

# Estadística descriptiva: Tipos de variables

## Cualitativas

Expresan una cualidad o propiedad que el objeto en estudio tiene o no, o bien lo tiene en distinto grado. Pueden ser **DICOTÓMICAS**: dos categorías o clases (ej: género al nacer) ó **POLICOTÓMICAS**: más de dos categorías (ej: nivel de estudios alcanzado)

## Cuantitativas

Asumen valores numéricos. Expresan una cantidad.

- ▶ **Discretas**: Surgen de contar. Son aquellas que sólo toman valores discretos dentro de su campo de variación (ej: cantidad de materias aprobadas)
- ▶ **Continuas**: Surgen de medir. Toman cualquier valor dentro de su rango de variación (ej: altura de un alumno).

# Algunos gráficos variables cualitativas:

## Gráfico de sectores




Figura: Número de comidas al día

## Gráfico de barras


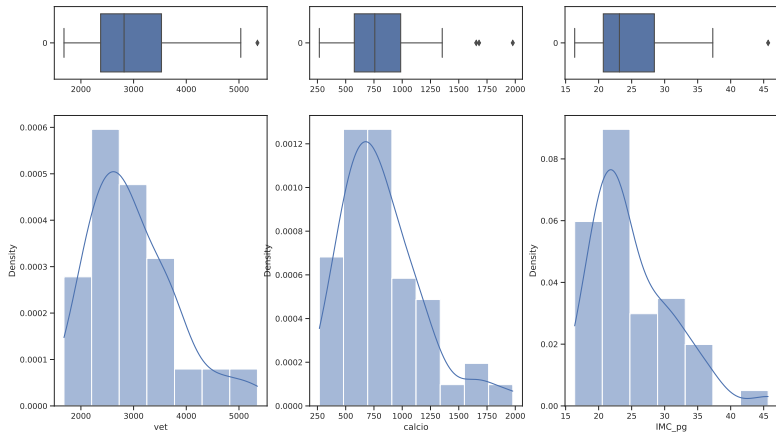



Figura: Número de comidas al día, discriminadas por estrato social

# Algunos gráficos variables cuantitativas: Histograma y boxplot



# Gráficos



# Medidas descriptivas numéricas - Caso univariado

- ▶ **Medidas de Tendencia Central** Valores numéricos que se obtienen de variables cuantitativas y cuyos resultados se localizan por el centro de la distribución. Ej: Media (promedio aritmético), Mediana, Moda.
- ▶ **Medidas de Posición:** Valores numéricos que permiten dividir la distribución de datos en partes iguales. Ej: Cuartiles, Deciles, Percentiles.
- ▶ **Medidas de Dispersión:** Valores numéricos que proporcionan una idea sobre cuan esparcidos o concentrados están los datos correspondientes a una variable. Ej: Rango, Rango intercuartílico, varianza, desviación estandar, coeficiente de variación.
- ▶ **Medidas de Forma:** Dan una idea de la forma de la distribución de la variable. Ej: Coeficiente de asimetría, de kurtosis (apuntamiento).

# Media y Varianza: Caso univariado, datos sin agrupar

$X$  variable en estudio,  $n$  tamaño de la muestra,  $x_1; \dots; x_n$  valores que asume la variable,

▶ **Media:**  $\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$

▶ **Varianza:**  $Var(x) = s_x^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}$

▶ **Desviación estándar:**  $\sqrt{s_x^2}$

## Caso multivariado: Matriz de Covarianza

$$\mathbf{S} = \frac{1}{n} \sum_{t=1}^n (\mathbf{x} - \bar{\mathbf{x}})^T (\mathbf{x} - \bar{\mathbf{x}})$$

donde :

Matriz de medias

$$\bar{\mathbf{x}} = \begin{bmatrix} \bar{x}_1 & \dots & \bar{x}_p \\ \vdots & \ddots & \vdots \\ \bar{x}_1 & \dots & \bar{x}_p \end{bmatrix}$$

Matriz de varianzas-covarianzas

$$\mathbf{S} = \begin{bmatrix} \text{Var}(x_1) & \dots & \text{Cov}(x_1, x_p) \\ \vdots & \ddots & \vdots \\ \text{Cov}(x_p, x_1) & \dots & \text{Var}(x_p) \end{bmatrix}$$


$$\text{Cov}(x_i, x_j) = s_{xy} = \frac{1}{n-1} \sum_{k=1}^n (x_i(t_k) - \bar{x}_i)(x_j(t_k) - \bar{x}_j)$$

De forma análoga, y teniendo en cuenta que

$$\text{Corr}(x_i, x_j) = \frac{\text{Cov}(x_i, x_j)}{s_{x_i} s_{x_j}} \text{ se construye la matriz de correlación.}$$



# Matriz de correlación - heatmap



# Conceptos básicos de Probabilidad

## Variable aleatoria

Una **Variable Aleatoria (v.a.)** unidimensional es una regla o función  $X$ , que asigna a cada elemento del espacio muestral (espacio de estados)  $\mathbf{S}$  un número (real),

$$X : \mathbf{S} \rightarrow \mathbb{R}_X$$

$R_X$  es el rango de la variable aleatoria.

- ▶ Si  $R_X$  finito o infinito numerable  $\Rightarrow X$  v.a. **discreta**
- ▶ Si existe  $(a, b)$  intervalo de números reales  $(a, b) \subset R_X$   
 $\Rightarrow X$  v.a. **continua**

# Variables aleatorias

## Función de distribución acumulada (cdf)

Sea  $(\mathbf{S}, \mathcal{A}, P)$  un espacio de probabilidad y sea  $X$  una v.a. definida sobre dicho espacio. La función  $F : \mathbb{R} \rightarrow [0, 1]$  definida por

$$F(x) = P(X \leq x)$$

es llamada **Función de distribución (de probabilidades) de  $X$**

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

Si  $X$  v.a. discreta que puede asumir los distintos valores  $x_1, x_2, \dots, x_n$  (o  $x_1, x_2, \dots$  si  $X$  puede asumir una cantidad infinita numerable de valores distintos) .

La **función de probabilidad de masa** de  $X$  es una función  $p : I \subseteq \mathbb{R} \rightarrow [0, 1]$  definida como  $p(x_i) = P(X = x_i) = P(\{\omega \in \mathbf{S} : X(\omega) = x_i\})$

## Función de densidad de probabilidades (pdf)

Si  $X$  v.a continua ,  $F_X(x) = P(X \leq x)$  su función de distribución acumulada, y si existe una función  $f(x) \geq 0$  tal que  $F_X(x) = \int_{-\infty}^x f(s)ds, \forall x \in \mathbb{R}$ , entonces  $f$  recibe el nombre de **función de densidad** (de probabilidades) de la v.a.  $X$ .

# Algunas distribuciones discretas

## Distribución Binomial

$$X \sim \mathcal{B}(n, p)$$


$X$  = número de éxitos observados en las  $n$  repeticiones de un experimento binomial,  $p$  = probabilidad de éxito en cada repetición

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

$$F(x) = P(X \leq x) =$$

$$\sum_{k=0}^x \binom{n}{k} p^k (1-p)^{n-k}$$

prob. masa dist. Binomial



# Algunas distribuciones discretas


## Distribución de Poisson

$X$  v.a que cuenta el número de eventos que ocurre en un intervalo de tiempo (espacio, volumen)  $\Rightarrow X$  tiene distribución de **Poisson de parámetro  $\lambda$** ,  $\lambda$  es la **tasa media** de ocurrencia del evento en un intervalo de tiempo, (espacio, volumen, etc.)

$$P(X = r) = \frac{\lambda^r}{r!} e^{-\lambda}, r = 0, 1, 2, \dots$$

$$E(X) = \lambda, \quad \text{Var}(X) = \lambda$$

prob. masa dist. Poisson



# Distribuciones continuas

## Distribución Gaussiana (Normal)

También conocida como **distribución gaussiana**, es una de las distribuciones más comunmente utilizadas por físicos, químicos e ingenieros ya que

- ▶ Si repite un experimento una cierta cantidad de veces entonces la variable que representa el promedio de los resultados tiene aproximadamente una distribución normal.
- ▶ Aparece en el estudio de numerosos fenómenos físicos (por ejemplo: velocidad de moléculas (Maxwell))
- ▶ Se la denomina “normal” porque representa un gran número de fenómenos en la naturaleza

# Distribución Normal

Si  $X$  es una v.a. con Distribución Normal con media  $\mu$  y desviación estándar  $\sigma$ , entonces  $X \sim N(\mu, \sigma^2)$



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

$$\blacktriangleright F(x) = \frac{1}{2} \left( 1 + \operatorname{erf} \left( \frac{x-\mu}{\sigma\sqrt{2}} \right) \right), \text{ con } \operatorname{erf}(x) = \frac{2}{\pi} \int_0^x e^{-t^2} dt$$

$$\blacktriangleright E(X) = \mu$$


$$\blacktriangleright V(X) = \sigma^2$$

# Distribución Normal





# Distribución Normal



# Estadística Inferencial: Estimación de parámetros

## Máxima Verosimilitud (estimación puntual)

### Definiciones:

Sean  $x_1, \dots, x_n$  realizaciones de  $X_1, \dots, X_n$ , muestra aleatoria de una v.a. con función de densidad (o probabilidad de masa)  $f(x)$  que involucra a algún parámetro  $\theta$  (la denotaremos  $f(x; \theta)$ ).

1. Se define la función de verosimilitud

$$\mathcal{L}(x_1, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i; \theta)$$

2. El **estimador de máxima verosimilitud** del parámetro  $\theta$  es el valor de  $\theta$  que maximiza la función  $\mathcal{L}(x_1, \dots, x_n; \theta)$

# Distribución Gaussiana univariada: estimación de $\mu$ y $\sigma^2$ por MV

Sean  $x_1, \dots, x_n$  observaciones de  $X_1, \dots, X_n$  muestra aleatoria de una v.a. con distribución normal  $N(\mu, \sigma^2)$ .

Recordar que  $f(x_i; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x_i - \mu)^2}{2\sigma^2}\right)$

Entonces:

$$\begin{aligned}\mathcal{L}(x_1, \dots, x_n; \mu, \sigma^2) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x_i - \mu)^2}{2\sigma^2}\right) \\ &= \frac{1}{\sigma^n (2\pi)^{n/2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right)\end{aligned}$$

## Estimación de $\mu$ y $\sigma^2$ por MV - continuación

- ▶ Los EMV se denotan por  $\hat{\mu}$  y  $\hat{\sigma}^2$
- ▶  $(\hat{\mu}, \hat{\sigma}^2) = \arg \max_{(\mu, \sigma^2)} \mathcal{L}(x_1, \dots, x_n; \mu, \sigma^2)$
- ▶ Resolver  $\frac{d \ln \mathcal{L}(x_1, \dots, x_n; \mu, \sigma^2)}{d\mu} = 0$  y  $\frac{d \ln \mathcal{L}(x_1, \dots, x_n; \mu, \sigma^2)}{d\sigma^2}$
- ▶ Resultan
  - ▶  $\hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i,$
  - ▶  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$

# Vectores Aleatorios

## Vectores Aleatorios

Sea  $(\mathbf{S}, \mathcal{A}, P)$  un espacio de probabilidad y sea  $n \in \mathbb{N}$ . Un **Vector Aleatorio n-dimensional**  $(X_1, X_2, \dots, X_n)$  es una aplicación del espacio muestral  $\mathbf{S}$  en  $\mathbb{R}^n = \mathbb{R} \times \mathbb{R} \dots \mathbb{R}$ , es decir

$$\begin{aligned}\mathbf{S} &\rightarrow \mathbb{R} \times \mathbb{R} \dots \times \mathbb{R} \\ \omega &\rightarrow (X_1(\omega), X_2(\omega), \dots, X_n(\omega))\end{aligned}$$

Cada componente del vector aleatorio es una variable aleatoria unidimensional.

## Vectores aleatorios bidimensionales

- ▶ Pueden modelarse dos v.a  $X$  e  $Y$  conjuntamente
- ▶  $F_{X,Y}(x, y) = P(X \leq x, Y \leq y)$  es la función de distribución acumulada conjunta
- ▶  $f_{XY}(x, y)$  ( $f_X(x)$ ,  $f_Y(y)$ ) es la densidad conjunta (marginales) de  $X$  e  $Y$

# Distribuciones Marginales

Si bien  $(X, Y)$  es un “vector aleatorio”, tanto  $X$  como  $Y$  son variables aleatorias unidimensionales, y como tales tienen su propia distribución.

## Distribuciones Marginales

Dada  $F_{XY}(x, y)$  función de distribución conjunta de  $(X, Y)$  se define la **función de distribución marginal de  $X$**  como

$$F_X(x) = P(X \leq x) = P(X \leq x, Y \leq +\infty), \quad x \in \mathbb{R}$$

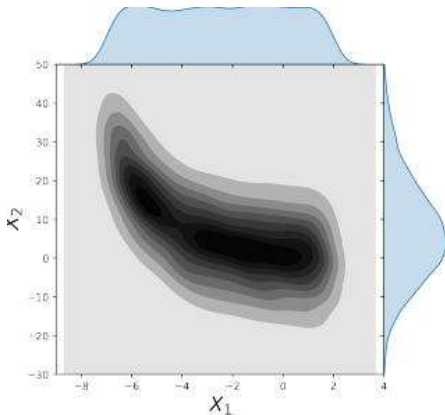
Análogamente, se define la **función de distribución marginal de  $Y$**  como

$$F_Y(y) = P(Y \leq y) = P(X \leq +\infty, Y \leq y), \quad y \in \mathbb{R}$$

## Densidad marginal caso continuo

$(X, Y)$  va continuo con función de densidad conjunta  $f(x, y)$ . Las **funciones de densidad marginales de X e Y** están dadas por

$$f_X(x) = \int_{-\infty}^{\infty} f(x, y) dy, \quad x \in \mathbb{R}, \quad f_Y(y) = \int_{-\infty}^{\infty} f(x, y) dx \quad y \in \mathbb{R}$$





# Distribuciones condicionadas (continuas)

## Distribuciones Condicionadas Continuas

Se definen la **función de densidad de X condicionada al valor y de Y** (y fijo) como


$$f_{X/Y=y}(x) = \frac{f_{XY}(x, y)}{f_Y(y)}, \quad x \in \mathbb{R}$$

y la **función de densidad de Y condicionada al valor x de X** (x fijo) como

$$f_{Y/X=x}(y) = \frac{f_{XY}(x, y)}{f_X(x)}, \quad y \in \mathbb{R}$$

donde  $f_X(x)$  y  $f_Y(y)$  son las densidades marginales de X e Y, respectivamente.

## Distribuciones condicionadas




# Covarianza y correlación

## Covarianza entre $X$ e $Y$

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

## Correlación entre $X$ e $Y$

$$\rho = \text{Corr}(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}$$



Dos variables  $X$  e  $Y$  son **independientes** si

$$f_{XY}(x, y) = f_X(x)f_Y(y)$$

**Observaciones:**

1. Si  $\sigma_{XY} = 0$  se dice que  $X$  e  $Y$  son **no correlacionadas** o **incorreladas**.
2.  $\rho_{XY}$  indica el grado de relación lineal entre las variables  $X$  e  $Y$ .
3. Si  $X$  e  $Y$  son independientes, entonces:
  - ▶ son no correlacionadas. (La recíproca no es cierta)
  - ▶  $f_{X/Y=y}(x) = f_X(x)$  y  $f_{Y/X=x}(y) = f_Y(y)$
  - ▶  $E(XY) = E(X)E(Y)$
  - ▶  $\text{Var}(aX+Y) = a^2\text{Var}(X) + \text{Var}(Y)$

# Distribución Gaussiana Bivariada $\mathcal{N}(\mu, \Sigma)$

$$\mu = E(\mathbf{X}) = [\mu_x, \mu_y]^T \quad \Sigma = \begin{bmatrix} \sigma_X^2 & \text{Cov}(X, Y) \\ \text{Cov}(Y, X) & \sigma_Y^2 \end{bmatrix}$$

Función de densidad de probabilidades

$$f_{X,Y}(x, y) = \frac{1}{2\pi\sqrt{|\Sigma|}} \exp\left(-\frac{1}{2} \left(\begin{bmatrix} x \\ y \end{bmatrix} - \begin{bmatrix} \mu_x \\ \mu_y \end{bmatrix}\right)^T \Sigma^{-1} \left(\begin{bmatrix} x \\ y \end{bmatrix} - \begin{bmatrix} \mu_x \\ \mu_y \end{bmatrix}\right)\right)$$

$$f_{X,Y}(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho^2}} \exp\left\{-\frac{1}{2\sigma_X^2\sigma_Y^2(1-\rho^2)} (\sigma_Y^2(x-\mu_X)^2 + \sigma_X^2(y-\mu_Y)^2 - 2\sigma_X\sigma_Y\rho(x-\mu_X)(y-\mu_Y))\right\}$$

# Distribución Gaussiana Bivariada $\mathcal{N}(\mu, \Sigma)$




Figura: pdf distribución Gaussiana bivariada


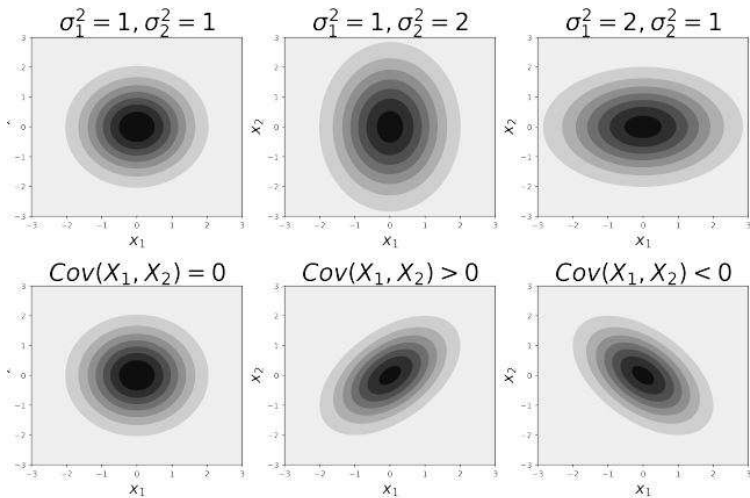



Figura: curvas nivel pdf distribución Gaussiana bivariada

# Distribución Gaussiana bivariada: matriz de covarianza $\Sigma$



# Propiedades de distribuciones Gaussianas

- ▶ Sean  $X_1$  y  $X_2$  dos variables aleatorias gaussianas
- ▶  $Y = X_1 + X_2$  también es gaussiana! (la suma de gaussianas, es gaussiana)



## Propiedades de la suma de variables aleatorias

- ▶  $E(X_1 + X_2) = E(X_1) + E(X_2) = \mu_1 + \mu_2$
- ▶  $Var(X_1 + X_2) = Var(X_1) + Va(X_2) + 2Cov(X_1, X_2)$



## Distribución Gaussiana multivariada $\mathcal{N}(\mu, \Sigma)$

El vector  $\mathbf{X} = (X_1, \dots, X_n)$  tiene **distribución Normal (Gaussiana) multivariada** si la función de densidad conjunta está dada por:

$$f_{\mathbf{X}}(x_1, x_2, \dots, x_n) = \frac{1}{2\pi^{|\Sigma|^{1/2}}} \exp\left(-\frac{1}{2}(\mathbf{x} - \mu)^T \Sigma^{-1}(\mathbf{x} - \mu)\right)$$

donde:

$\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ ,  $\mu = [\mu_{X_1}, \dots, \mu_{X_n}]^T$  es el vector de medias y  $\Sigma$  es a matriz de varianza-covarianza de las  $X_i$ , y  $|\Sigma|$  es el determinante de esa matriz.

### Observaciones

- ▶ No hay una expresión analítica para las funciones de verosimilitud.
- ▶ Para estimar  $\mu$  y  $\Sigma$  deben usarse otros métodos o técnicas (ej. algoritmo EM)

# Comentarios

- ▶ Ejercicios y ejemplos de esta unidad en notebooks jupyter disponibles en página curso
- ▶ Bibliografía sugerida: Bishop C., 2006: Pattern Recognition and Machine Learning. Springer