

## **DISTRIBUCIONES MULTIVARIADAS**

ALAN REYES-FIGUEROA  
APRENDIZAJE ESTADÍSTICO

(AULA 04) 17.ENERO.2024

# Distribuciones multivariadas

Sea  $X = (X_1, X_2, \dots, X_d) \in \mathbb{R}^d$  un vector aleatorio (esto es, cada componente  $X_i$  es una variable aleatoria  $X_i : \Omega \rightarrow \mathbb{R}$ ).

## Definición

Definimos el **valor esperado** de  $X$  como el vector  $\mu \in \mathbb{R}^d$  dado por

$$\mathbb{E}(X) = \mu = (\mu_1, \mu_2, \dots, \mu_d)^T \in \mathbb{R}^d,$$

donde  $\mu_i = \mathbb{E}(X_i)$ , para  $i = 1, 2, \dots, d$ .

## Definición

Definimos la **varianza** de  $X$  como la matriz  $\Sigma \in \mathbb{R}^{d \times d}$  dada por

$$\text{Var}(X) = \Sigma = (\text{Cov}(X_i, X_j))_{i,j}.$$

La entrada  $(i, j)$  de esta matriz corresponde a la covarianza de las variables  $X_i$  y  $X_j$ . A  $\Sigma$  también se le conoce como la **matriz de covarianza** de  $X$ .

## Propiedades

Para cualquier vector aleatorio  $X \in \mathbb{R}^d$ , la matriz de covarianzas  $\Sigma = \text{Var}(X)$  satisface

1.  $\Sigma$  es simétrica (como consecuencia, tiene autovalores reales).
2.  $\Sigma$  es semi-definida positiva (todos sus autovalores son no-negativos).  
En particular, para todo vector  $\mathbf{x} \in \mathbb{R}^d$ , se cumple que  $\mathbf{x}^T \Sigma \mathbf{x} \geq 0$ .
3. La diagonal de  $\Sigma$  contiene a las varianzas  $\sigma_i^2 = \text{Var}(X_i)$ , para  $i = 1, 2, \dots, d$ .

# Distribuciones multivariadas

Sea  $X_1, X_2, \dots, X_n \in \mathbb{R}^d$  es una muestra aleatoria de vectores i.i.d (independientes e idénticamente distribuidos), todos con distribución  $X$ . Podemos codificar esta muestra dentro de una matriz,  $\mathbb{X} \in \mathbb{R}^{n \times d}$ , llamada la **matriz de datos** (cada dato de la muestra es un renglón de  $\mathbb{X}$ ).

$$\mathbb{X} = \begin{pmatrix} X_{11} & X_{12} & \dots & X_{1d} \\ X_{21} & X_{22} & \dots & X_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ X_{n1} & X_{n2} & \dots & X_{nd} \end{pmatrix},$$

donde

$$X_i = (x_{i1}, x_{i2}, \dots, x_{id}) \in \mathbb{R}^d, \quad i = 1, 2, \dots, n.$$

# Distribuciones multivariadas

Observe que la  $i$ -ésima columna de  $\mathbb{X}$  corresponde a una muestra (de tamaño  $n$ ) de la variable aleatoria  $X_i$ . Podemos entonces restar a cada columna su correspondiente media  $\mu_i = \mathbb{E}(X_i)$ . Así, obtenemos una versión centrada de la matriz de datos:

$$\mathbb{X}_c = \mathbb{X} - \mu = \begin{pmatrix} X_{11} - \mu_1 & X_{12} - \mu_2 & \dots & X_{1d} - \mu_d \\ X_{21} - \mu_1 & X_{22} - \mu_2 & \dots & X_{2d} - \mu_d \\ \vdots & \vdots & \ddots & \vdots \\ X_{n1} - \mu_1 & X_{n2} - \mu_2 & \dots & X_{nd} - \mu_d \end{pmatrix}.$$

Es posible mostrar (con las propiedades de la página siguiente) que la matriz de covarianzas empírica (muestral) se puede escribir como

$$\Sigma = \text{Var}(X) = \mathbb{X}_c^T \mathbb{X}_c.$$

## Propiedades

Sea  $X, Y \in \mathbb{R}^d$  vectores aleatorios,  $a, b \in \mathbb{R}$ ,  $c \in \mathbb{R}^d$  constantes,  $A \in \mathbb{R}^{p \times d}$  una matriz constante. Entonces

1.  $\mathbb{E}(aX + bY) = a\mathbb{E}(X) + b\mathbb{E}(Y)$ ,
2.  $\mathbb{E}(c) = c$ ,
3.  $\mathbb{E}(\mathbb{E}(X)) = \mathbb{E}(X)$ ,
4.  $\text{Var}(aX) = a^2\text{Var}(X)$ ,
5.  **$\text{Var}(AX) = A^T\text{Var}(X)A$** ,
6.  $\text{Var}(aX + bY) = a^2\text{Var}(X) + b^2\text{Var}(Y) + 2ab\text{Cov}(X, Y)$ ,
7. Si  $X \perp Y$ , entonces  $\text{Cov}(X, Y) = 0$ ,
8. Si  $X \perp Y$ , entonces  $\text{Var}(aX + bY) = a^2\text{Var}(X) + b^2\text{Var}(Y)$ .

# Distribución normal multivariada

Sea  $X = (X_1, X_2, \dots, X_d) \in \mathbb{R}^d$  un vector aleatorio. Decimos que  $X$  sigue una **distribución normal multivariada**  $\mathcal{N}_d(\mu, \Sigma)$  si su densidad está dada por

$$f_X(\mathbf{x}) = \int_{\mathbb{R}^d} \frac{1}{(2\pi)^{d/2} \sqrt{|\Sigma|}} \exp\left(-\frac{1}{2}(\mathbf{x} - \mu)^T \Sigma^{-1}(\mathbf{x} - \mu)\right) d\mathbf{x}.$$



Aquí,

$$\mathbb{E}(X) = \mu = (\mu_1, \mu_2, \dots, \mu_d)^T,$$

y

$$\text{Var}(X) = \Sigma = \begin{pmatrix} \text{Cov}(X_1, X_1) & \text{Cov}(X_1, X_2) & \dots & \text{Cov}(X_1, X_d) \\ \text{Cov}(X_2, X_1) & \text{Cov}(X_2, X_2) & \dots & \text{Cov}(X_2, X_d) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(X_d, X_1) & \text{Cov}(X_d, X_2) & \dots & \text{Cov}(X_d, X_d) \end{pmatrix}.$$

# Distribución normal multivariada



Densidad de una normal bivariada: (a) como nube de puntos, (b) como función.

# Distribución normal multivariada


Típicamente la matriz  $\Sigma$  proporciona información sobre la relación entre las variables componentes.

$Cov(X) = [Cov(X_i, X_j)]$  es una matriz simétrica y pos. definida.

Caso  $d = 2$ :

$$\begin{pmatrix} Var(X_1) & Cov(X_1, X_2) \\ Cov(X_1, X_2) & Var(X_2) \end{pmatrix} = \begin{pmatrix} \sigma_{X_1}^2 & Cor(X_1, X_2)\sigma_{X_1}\sigma_{X_2} \\ Cor(X_1, X_2)\sigma_{X_1}\sigma_{X_2} & \sigma_{X_2}^2 \end{pmatrix}$$


Cambiar  $\rho = Cor(X_1, X_2)$ :



<http://personal.kenyon.edu/hartlaub/MellonProject/images/Bivariate52.gif>

# Distribución normal multivariada

Una forma práctica de ver esta información de covarianza o correlación entre las componentes es a través de *pair-plots*.



Pairplot de una muestra para una normal 3-variada.

# Distribución normal multivariada

Problema: ¿Cómo generar una muestra de una distribución normal  $d$ -variada con  $\mu$  y  $\Sigma$  específicas?

Algoritmo (o receta):

1. Generar  $d$  muestras (de tamaño  $n$ ), independientes, de distribuciones normales estándar  $Z_1, Z_2, \dots, Z_d \in \mathbb{R}^n$ , y construir una matriz de datos  $\mathbb{Z}$  con las muestras  $Z_i$  como columnas.

Como son independientes y estándar el vector  $Z = (Z_1, \dots, Z_d)$  sigue una distribución normal estándar  $\mathcal{N}_d(\mathbf{0}, I_d)$ .

2. Asegurarse que la matriz  $\Sigma$  es simétrica y positiva definida. Luego, construir descomposición de Cholesky  $L^T L = \Sigma$ , (el algoritmo que vieron en análisis numérico).

3. Construir la variable aleatoria  $X = LZ + \mu$ , la cual tiene una matriz de datos dada por  $\mathbb{X} = L\mathbb{Z} + \mu$  (la muestra que queremos). De las propiedades anteriores, tenemos que  $\mathbb{E}(Z) = \mu$  y  $\text{Var}(X) = L^T I_d L = L^T L = \Sigma$ .

# Esperanza

Promedio: Sea una variable aleatoria continua  $X$  con densidad  $f_X$ . La **esperanza** (*expectativa, valor esperado*) de  $X$  se define como

$$\mathbb{E}(X) = \int_{\mathbb{R}} t f_X(t) dt$$

en caso de que la integral exista.

Mediana: Una **mediana** de  $X$  es cualquier valor  $t \in \mathbb{R}$  que satisface  $F_X(t) = \frac{1}{2}$ . Dicho de otra manera, son las preimágenes  $F_X^{-1}(1/2)$ .

**Obs!**  $F_X$  no siempre es invertible!! Denotamos  $Q_X : [0, 1] \rightarrow \overline{\mathbb{R}}$  a la *función de cuantiles*, la inversa generalizada de  $F_X$ :

$$Q_X(\alpha) = \inf\{x \in \mathbb{R} : \alpha \leq F_X(x)\}, \quad \text{para } 0 < \alpha < 1.$$

Moda: Una **moda** de la distribución de  $X$  es cualquier máximo local de  $f_X$ .

# Esperanza condicional

Recordemos que dadas  $X, Y$  v.a. continuas

$$f_{X|Y}(x | y) = \frac{f_{X,Y}(x, y)}{f_Y(y)}.$$

Entonces

$$\mathbb{P}(a \leq X \leq b | Y = y) = \int_a^b f_{X|Y}(x | y) dx.$$

Como estamos condicionando a un evento con probabilidad cero, en realidad la ecuación anterior debe entenderse como un límite

$$\mathbb{P}(a \leq X \leq b | Y = y) = \lim_{\epsilon \rightarrow 0^+} \mathbb{P}(a \leq X \leq b | |Y - y| < \epsilon).$$

## Definición

Para las v.a.  $X$  y  $Y$  continuas, se define la **esperanza condicional** de  $X$  dado que  $Y$  como

$$\mathbb{E}(X | Y) = \int_{\mathbb{R}} t f_{X|Y}(t) dt.$$

## Proposición (Ley de la probabilidad total para esperanzas)

Sean  $X, Y$  v.a. continuas, entonces

$$\mathbb{E}(X | Y) = \int_{\mathbb{R}} \mathbb{E}(X | Y = y) f_Y(y) dy.$$

## Definición

Sea  $X$  una v.a. continua. Definimos su **varianza** como:

$$\text{Var}(X) = \mathbb{E}[(X - \mathbb{E}X)^2] = \int_{\mathbb{R}} (t - \mu_X)^2 f_X(t) dt,$$

en caso de que este valor esperado exista.

Propiedades:

- $\text{Var}(X) \geq 0$ .
- $\text{Var}(aX) = a^2 \text{Var}(X)$ .
- Si  $X_1, X_2$  son independientes, entonces

$$\text{Var}(aX_1 + bX_2) = a^2 \text{Var}(X_1) + b^2 \text{Var}(X_2).$$

## Definición

Dada dos v.a.  $X_1, X_2$  continuas (definidas sobre el mismo espacio).  
Definimos su **covarianza** como:

$$\text{Cov}(X_1, X_2) = \mathbb{E}[(X_1 - \mathbb{E}X_1)(X_2 - \mathbb{E}X_2)] = \int_{\mathbb{R}} \int_{\mathbb{R}} (s - \mu_X)(t - \mu_Y) f_X(s) f_Y(t) ds dt,$$

en caso de que este valor esperado exista.

## Propiedades:

- $\text{Cov}(X_1, X_2) = \text{Cov}(X_2, X_1)$ .
- $\text{Cov}(aX, bY) = ab\text{Cov}(X, Y)$ .
- $\text{Cov}(aX, X) = a\text{Var}(X)$ .
- Si  $X_1, X_2$  son independientes, entonces  $\text{Cov}(X_1, X_2) = 0$ .

## Definición

Sea  $X$  una v.a. continua. Definimos su **entropía de Shannon** como:

$$H(X) = - \int_{\mathbb{R}} f_X(t) \log f_X(t) dt.$$

En ocasiones esta es llamada *entropía diferencial*.

Comentario: No estoy seguro si existe un análogo a la entropía de Gini en el caso continuo.

## Definición

Sean  $X, Y$  dos variables aleatorias, la **entropía condicional** de  $X$  dado  $Y$  es

$$H_Y(X) = \mathbb{E}H(X | Y) = - \int_{\mathbb{R}} \int_{\mathbb{R}} f_{X|Y}(s | t) \log f_{X|Y}(s | t) f_Y(t) ds dt.$$

**Obs.** No es simétrica:  $H_Y(X) \neq H_X(Y)$ .

## Definición

Sean  $X, Y$  dos variables aleatorias, la **información mutua** de  $X$  y  $Y$  está dada por

$$I(X, Y) = H(X) - H_Y(X).$$

## Proposición


$$I(X, Y) = I(Y, X).$$

# Entropía

## Definición

La **entropía conjunta** de  $X$  y  $Y$  es

$$H(X, Y) = - \int_{\mathbb{R}} \int_{\mathbb{R}} f_{X,Y}(s, t) \log f_{X,Y}(s, t) ds dt.$$



Vale el mismo diagrama que en el caso discreto.

## Definición

Sean  $P$  una distribución continua de probabilidad, con densidad  $f_P(x)$ . La **entropía** de  $P$  es

$$H(P) = - \int_{\mathbb{R}} f_P(x) \log f_P(x) dx.$$

## Definición

Sean  $P, Q$  dos distribuciones discretas de probabilidad, la **entropía cruzada** (cross-entropy) de  $P$  y  $Q$  es

$$H(P, Q) = - \int_{\mathbb{R}} f_P(x) \log f_Q(x) dx.$$

Además, la **divergencia de Kullback-Leibler** de  $P$  y  $Q$  se define como

$$\begin{aligned} D_{KL}(P \parallel Q) &= - \int_{\mathbb{R}} f_P(x) \log \frac{f_Q(x)}{f_P(x)} dx \\ &= - \int_{\mathbb{R}} f_P(x) \log f_Q(x) dx + \sum_x f_P(x) \log f_P(x) dx = H(P, Q) - H(P). \end{aligned}$$