

Tema 3

Normalidad multivariante

Aurea Grané
Departamento de Estadística
Universidad Carlos III de Madrid

3 Normalidad multivariante

1. Distribuciones de probabilidad multivariantes
2. La distribución normal multivariante
3. Distribuciones relacionadas con la distribución normal multivariante
4. Aplicación a la inferencia multivariante

3.1 Distribuciones de probabilidad multivariantes

Funciones de distribución y de densidad conjuntas

Sea $\mathbf{X} = (X_1, X_2, \dots, X_p)'$ un vector aleatorio $p \times 1$.

Se define la **función de distribución conjunta** de \mathbf{X} (o función de probabilidad acumulada) en el punto $\mathbf{x} = (x_1, x_2, \dots, x_p)' \in \mathbb{R}^p$ como

$$F(\mathbf{x}) = \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} \dots \int_{-\infty}^{x_p} f(\mathbf{t}) dt_1 dt_2 \dots dt_p,$$

donde $\mathbf{t} = (t_1, t_2, \dots, t_p) \in \mathbb{R}^p$.

La función $f(\mathbf{t})$ se denomina **función de densidad conjunta** de \mathbf{X} y verifica que:

- $f(\mathbf{t}) = f(t_1, t_2, \dots, t_p) \geq 0, \forall \mathbf{t} \in \mathbb{R}^p$,
- $\int_{\mathbb{R}^p} f(\mathbf{t}) dt_1 dt_2 \dots dt_p = 1$.

Distribuciones marginales

Dado el vector aleatorio $\mathbf{X} = (X_1, X_2, \dots, X_p)'$, la **función de densidad marginal** de la variable aleatoria X_j , para $j = 1, \dots, p$, se obtiene integrando la densidad conjunta:

$$f_{X_j}(x_j) = \int_{\mathbb{R}^{p-1}} f(t_1, t_2, \dots, t_p) dt_1 \dots dt_{j-1} dt_{j+1} \dots dt_p.$$

La función $f_{X_j} : \mathbb{R} \rightarrow [0, +\infty)$ y cumple que $\int_{\mathbb{R}} f_{X_j}(t) dt = 1$.

De forma más general, dada una partición del vector $\mathbf{X} = (\mathbf{X}'_1, \mathbf{X}'_2)'$, donde $\mathbf{X}_1 = (X_1, \dots, X_{p_1})'$ y $\mathbf{X}_2 = (X_{p_1+1}, \dots, X_p)'$, la **función de densidad marginal** de \mathbf{X}_1 se obtiene:

$$f_{\mathbf{X}_1}(x_1, \dots, x_{p_1}) = \int_{\mathbb{R}^{p_2}} f(t_1, t_2, \dots, t_p) dt_{p_1+1} \dots dt_p, \quad \text{donde } p_2 = p - p_1.$$

La función $f_{\mathbf{X}_1} : \mathbb{R}^{p_1} \rightarrow [0, +\infty)$ y $\int_{\mathbb{R}^{p_1}} f_{\mathbf{X}_1}(t_1, \dots, t_{p_1}) dt_1 \dots dt_{p_1} = 1$.

Análogamente se obtiene la función de densidad marginal de \mathbf{X}_2 , dando lugar a una función $f_{\mathbf{X}_2} : \mathbb{R}^{p_2} \rightarrow [0, +\infty)$.

Distribuciones condicionadas

Consideremos la misma partición del vector $\mathbf{X} = (\mathbf{X}'_1, \mathbf{X}'_2)'$, donde $\mathbf{X}_1 = (X_1, \dots, X_{p_1})'$, $\mathbf{X}_2 = (X_{p_1+1}, \dots, X_p)'$ y $p_2 = p - p_1$.

Supongamos que se conoce un valor determinado del vector \mathbf{X}_2 , es decir, $\mathbf{X}_2 = \mathbf{x}_2^0 = (x_{p_1+1}^0, \dots, x_p^0) \in \mathbb{R}^{p_2}$. Entonces, la **función de densidad** de \mathbf{X}_1 **condicionada** a que $\mathbf{X}_2 = \mathbf{x}_2^0$ se obtiene como

$$f_{\mathbf{X}_1|\mathbf{X}_2=\mathbf{x}_2^0}(\mathbf{x}_1) = \frac{f(\mathbf{x}_1, \mathbf{x}_2^0)}{f_{\mathbf{X}_2}(\mathbf{x}_2^0)} = \frac{f(x_1, \dots, x_{p_1}, x_{p_1+1}^0, \dots, x_p^0)}{f_{\mathbf{X}_2}(x_{p_1+1}^0, \dots, x_p^0)},$$

que da lugar a una función de \mathbb{R}^{p_1} en $[0, +\infty)$.

Esperanza, covarianza y correlación

Sea $\mathbf{X} = (X_1, X_2, \dots, X_p)'$ un vector aleatorio con función de densidad conjunta $f(\mathbf{x})$.

La **esperanza** (o primer momento) de \mathbf{X} se define como el vector de esperanzas de las variables aleatorias que lo forman, es decir,

$$\boldsymbol{\mu} = \mathbf{E}(\mathbf{X}) = (\mathbf{E}(X_1), \mathbf{E}(X_2), \dots, \mathbf{E}(X_p))' \in \mathbb{R}^p,$$

donde $\mathbf{E}(X_j) = \int_{\mathbb{R}} t f_{X_j}(t) dt$, para $j = 1, \dots, p$.

El segundo momento de \mathbf{X} se define como la matriz que contiene los segundos momentos de las variables aleatorias que forman el vector

$$\boldsymbol{\mu}_2 = \mathbf{E}(\mathbf{X}\mathbf{X}') = \begin{pmatrix} \mathbf{E}(X_1^2) & \mathbf{E}(X_1X_2) & \dots & \mathbf{E}(X_1X_p) \\ \mathbf{E}(X_2X_1) & \mathbf{E}(X_2^2) & \dots & \mathbf{E}(X_2X_p) \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{E}(X_pX_1) & \mathbf{E}(X_pX_2) & \dots & \mathbf{E}(X_p^2) \end{pmatrix}_{p \times p}$$

donde $\mathbf{E}(X_j^2) = \int_{\mathbb{R}} t^2 f_{X_j}(t) dt$ y $\mathbf{E}(X_jX_k) = \int_{\mathbb{R}^2} t s f_{(X_j, X_k)}(t, s) dt ds$.

La **covarianza** de \mathbf{X} se define como

$$\boldsymbol{\Sigma} = \text{Cov}(\mathbf{X}) = \mathbf{E}((\mathbf{X} - \boldsymbol{\mu})(\mathbf{X} - \boldsymbol{\mu})') = \boldsymbol{\mu}_2 - \boldsymbol{\mu}\boldsymbol{\mu}',$$

que da lugar a la siguiente matriz de covarianzas

$$\boldsymbol{\Sigma} = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{p1} & \sigma_{p2} & \dots & \sigma_{pp} \end{pmatrix}, \text{ con } \sigma_{jk} = \begin{cases} \mathbf{E}(X_j^2) - (\mathbf{E}(X_j))^2, & \text{si } j = k, \\ \mathbf{E}(X_jX_k) - \mathbf{E}(X_j)\mathbf{E}(X_k), & \text{si } j \neq k. \end{cases}$$

Observación 1 La diagonal de $\boldsymbol{\Sigma}$ contiene las varianzas de las X_j 's, mientras que fuera de la diagonal están las covarianzas de los pares de variables. Para las varianzas también se utiliza la siguiente notación alternativa $\sigma_{jj} = \sigma_j^2 = \text{var}(X_j)$. Además hay que recordar que $\text{var}(X_j) = \text{cov}(X_j, X_j)$.

La matriz $\boldsymbol{\Sigma}$ es simétrica y semidefinida positiva.

La **correlación** de \mathbf{X} se define a partir de la matriz de covarianzas

$$\mathbf{P} = \text{Corr}(\mathbf{X}) = \mathbf{D}_\sigma^{-1} \boldsymbol{\Sigma} \mathbf{D}_\sigma^{-1},$$

donde $\mathbf{D}_\sigma = \text{diag}(\sqrt{\sigma_{11}}, \dots, \sqrt{\sigma_{pp}}) = \text{diag}(\sigma_1, \dots, \sigma_p)$, dando lugar a la siguiente matriz de correlaciones

$$\mathbf{P} = \begin{pmatrix} 1 & \rho_{12} & \dots & \rho_{1p} \\ \rho_{21} & 1 & \dots & \rho_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{p1} & \rho_{p2} & \dots & 1 \end{pmatrix}, \text{ con } \rho_{jk} = \text{corr}(X_j, X_k) = \frac{\sigma_{jk}}{\sigma_j \sigma_k}.$$

La matriz \mathbf{P} es simétrica y semidefinida positiva.

Variables aleatorias (compuestas)

Sea \mathbf{X} un vector aleatorio con esperanza $\boldsymbol{\mu}$ y covarianza $\boldsymbol{\Sigma}$.

Consideremos la variable aleatoria (compuesta) $Y = \mathbf{a}'\mathbf{X}$, donde $\mathbf{a} \in \mathbb{R}^p$, es decir, Y es una combinación lineal de las componentes del vector aleatorio \mathbf{X} .

La esperanza y varianza de Y son

$$\begin{aligned} E(Y) &= E(\mathbf{a}'\mathbf{X}) = \mathbf{a}' E(\mathbf{X}) = \mathbf{a}'\boldsymbol{\mu} \in \mathbb{R}, \\ \text{var}(Y) &= \text{var}(\mathbf{a}'\mathbf{X}) = \text{cov}(\mathbf{a}'\mathbf{X}, \mathbf{a}'\mathbf{X}) = E((\mathbf{a}'\mathbf{X} - E(\mathbf{a}'\mathbf{X}))(\mathbf{a}'\mathbf{X} - E(\mathbf{a}'\mathbf{X}))') \\ &= E((\mathbf{a}'\mathbf{X} - \mathbf{a}'\boldsymbol{\mu})(\mathbf{a}'\mathbf{X} - \mathbf{a}'\boldsymbol{\mu})') = \mathbf{a}' E((\mathbf{X} - \boldsymbol{\mu})(\mathbf{X} - \boldsymbol{\mu})') \mathbf{a} = \mathbf{a}'\boldsymbol{\Sigma}\mathbf{a}. \end{aligned}$$

Si $Z = \mathbf{b}'\mathbf{X}$ es otra variable compuesta, con $\mathbf{b} \in \mathbb{R}^p$, entonces la covarianza entre Y y Z es

$$\begin{aligned} \text{cov}(Y, Z) &= \text{cov}(\mathbf{a}'\mathbf{X}, \mathbf{b}'\mathbf{X}) = E((\mathbf{a}'\mathbf{X} - E(\mathbf{a}'\mathbf{X}))(\mathbf{b}'\mathbf{X} - E(\mathbf{b}'\mathbf{X}))') \\ &= E((\mathbf{a}'\mathbf{X} - \mathbf{a}'\boldsymbol{\mu})(\mathbf{b}'\mathbf{X} - \mathbf{b}'\boldsymbol{\mu})') \\ &= \mathbf{a}' E((\mathbf{X} - \boldsymbol{\mu})(\mathbf{X} - \boldsymbol{\mu})') \mathbf{b} = \mathbf{a}'\boldsymbol{\Sigma}\mathbf{b} = \mathbf{b}'\boldsymbol{\Sigma}\mathbf{a}. \end{aligned}$$

3.2 La distribución normal multivariante

Toda variable aleatoria $X \sim N(\mu, \sigma)$ puede expresarse como $X = \mu + \sigma Z$, donde $Z \sim N(0, 1)$. La generalización de esta propiedad en dimensión $p > 1$ permite definir la distribución normal multivariante.

Se dice que $\mathbf{X} = (X_1, X_2)'$ tiene ley **normal bivalente** con

parámetros $\boldsymbol{\mu} = (\mu_1, \mu_2)'$ y $\boldsymbol{\Sigma} = \begin{pmatrix} \sigma_1^2 & \sigma_1\sigma_2\rho \\ \sigma_1\sigma_2\rho & \sigma_2^2 \end{pmatrix}$, y se denotará

como $\mathbf{X} \sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, si

$$\begin{pmatrix} X_1 \\ X_2 \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix} + \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \begin{pmatrix} Z_1 \\ Z_2 \end{pmatrix}$$

donde Z_1, Z_2 son variables aleatorias independientes con ley $N(0, 1)$. Los coeficientes a_{ij} (para $j = 1, 2$) vienen determinados por los parámetros $\sigma_1^2 = \text{var}(X_1)$, $\sigma_2^2 = \text{var}(X_2)$, $\rho = \text{corr}(X_1, X_2)$.

La función de densidad de probabilidad de $\mathbf{X} \sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ en el punto $(x_1, x_2) \in \mathbb{R}^2$ es

$$f(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp\left\{-\frac{1}{2}Q(x_1, x_2)\right\},$$

donde $Q(x_1, x_2)$ es la forma cuadrática siguiente:

$$Q(x_1, x_2) = \frac{1}{1-\rho^2} \left(\frac{(x_1 - \mu_1)^2}{\sigma_1^2} - 2\rho \frac{(x_1 - \mu_1)(x_2 - \mu_2)}{\sigma_1\sigma_2} + \frac{(x_2 - \mu_2)^2}{\sigma_2^2} \right)$$

Observación 2 Si $\rho = 0$ (X_1 y X_2 están incorreladas), entonces

$$\begin{aligned} f(x_1, x_2) &= \frac{1}{2\pi\sigma_1\sigma_2} \exp\left\{-\frac{1}{2} \left(\frac{(x_1 - \mu_1)^2}{\sigma_1^2} + \frac{(x_2 - \mu_2)^2}{\sigma_2^2} \right)\right\} \\ &= \frac{1}{2\pi\sigma_1} \exp\left\{-\frac{1}{2} \frac{(x_1 - \mu_1)^2}{\sigma_1^2}\right\} \frac{1}{2\pi\sigma_2} \exp\left\{-\frac{1}{2} \frac{(x_2 - \mu_2)^2}{\sigma_2^2}\right\} \\ &= f_{X_1}(x_1) f_{X_2}(x_2), \end{aligned}$$

donde $f_{X_1}(x_1)$ y $f_{X_2}(x_2)$ son las funciones de densidad marginales de dos v.a. con leyes $N(\mu_1, \sigma_1^2)$ y $N(\mu_2, \sigma_2^2)$, respectivamente.

En la Observación anterior hemos demostrado que si $\mathbf{X} = (X_1, X_2)'$ $\sim N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ y $\rho = \text{corr}(X_1, X_2) = 0$, entonces las variables aleatorias X_1 y X_2 son **normales** e **independientes**. (Recordad que esto último se debe a que la función de densidad conjunta puede expresarse como el producto de las funciones de densidad marginales).

La implicación contraria siempre es cierta. Es decir, si X_1 y X_2 son variables aleatorias independientes, entonces $\text{corr}(X_1, X_2) = 0$. (Recordad que $\text{corr}(X_1, X_2) = \sigma_{12}/(\sigma_1\sigma_2)$ donde $\sigma_{12} = E(X_1X_2) - E(X_1)E(X_2)$. Cuando X_1 y X_2 son v.a. independientes se cumple que $E(X_1X_2) = E(X_1)E(X_2)$).

Acabamos de demostrar (para el caso $p = 2$) que **bajo el modelo de normalidad multivariante, incorrelación equivale a independencia**.

Generalización al caso multivariante

Se dice que el vector $\mathbf{X} = (X_1, \dots, X_p)'$ tiene ley **normal p -variante** si existen p variables aleatorias independientes con ley $N(0, 1)$, Z_1, Z_2, \dots, Z_p , tales que

$$\mathbf{X} = \boldsymbol{\mu} + \mathbf{A} \mathbf{Z},$$

donde $\mathbf{Z} = (Z_1, \dots, Z_p)'$, $\boldsymbol{\mu} = (\mu_1, \dots, \mu_p)'$ y \mathbf{A} es una matrix $p \times p$.

Propiedades:

1. La esperanza y covarianza del vector $\mathbf{X} = \boldsymbol{\mu} + \mathbf{A} \mathbf{Z}$ son

$$\mathbf{E}(\mathbf{X}) = \boldsymbol{\mu}, \quad \text{Var}(\mathbf{X}) = \mathbf{A}' \mathbf{A} = \boldsymbol{\Sigma}.$$

Utilizaremos la notación $\mathbf{X} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$. Observad que $\boldsymbol{\Sigma} \geq 0$. Además, $\boldsymbol{\Sigma} > 0$ si $\text{rang}(\mathbf{A}) = p$.

Observación 3 Esta propiedad se utiliza para generar muestras de un vector aleatorio $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ con $\boldsymbol{\Sigma} = \mathbf{A}' \mathbf{A}$.

2. Si \mathbf{X} es no singular, su función de densidad de probabilidad en el punto $\mathbf{x} \in \mathbb{R}^p$ es

$$f(\mathbf{x}) = \frac{|\boldsymbol{\Sigma}|^{-1/2}}{(2\pi)^{p/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\},$$

donde $(\mathbf{x} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})$ es el cuadrado de la **distancia de Mahalanobis** del punto \mathbf{x} al centro de la distribución $\boldsymbol{\mu}$.

3. Todo vector \mathbf{Y} obtenido como combinación lineal de \mathbf{X} tiene ley normal multivariante. En particular, todo subconjunto de \mathbf{X} tiene ley normal multivariante y las marginales X_1, \dots, X_p son normales univariantes.
4. Para variables aleatorias con distribución conjunta normal multivariante, incorrelación equivale a independencia.
5. Si $\mathbf{X} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ es no singular, la variable aleatoria

$$U_p = (\mathbf{X} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{X} - \boldsymbol{\mu}) \sim \chi_p^2.$$

6. Consideremos la siguiente partición del vector $\mathbf{X} = (\mathbf{X}'_1, \mathbf{X}'_2)'$, donde $\mathbf{X}_1 = (X_1, \dots, X_{p_1})'$, $\mathbf{X}_2 = (X_{p_1+1}, \dots, X_p)'$ y $p_2 = p - p_1$. Sean $\boldsymbol{\mu}_1 = \mathbf{E}(\mathbf{X}_1)$ y $\boldsymbol{\mu}_2 = \mathbf{E}(\mathbf{X}_2)$ los vectores de esperanzas. La matriz de covarianzas de \mathbf{X} puede particionarse en bloques como:

$$\boldsymbol{\Sigma} = \begin{pmatrix} \boldsymbol{\Sigma}_{11} & \boldsymbol{\Sigma}_{12} \\ \boldsymbol{\Sigma}_{21} & \boldsymbol{\Sigma}_{22} \end{pmatrix},$$

donde $\boldsymbol{\Sigma}_{11} = \text{Var}(\mathbf{X}_1)$, $p_1 \times p_1$, $\boldsymbol{\Sigma}_{22} = \text{Var}(\mathbf{X}_2)$, $p_2 \times p_2$, $\boldsymbol{\Sigma}_{12} = \text{Cov}(\mathbf{X}_1, \mathbf{X}_2)$, $p_1 \times p_2$, y $\boldsymbol{\Sigma}_{21} = \boldsymbol{\Sigma}'_{12}$.

La **distribución** de \mathbf{X}_1 **condicionada** a $\mathbf{X}_2 = \mathbf{x}_2^0$ es normal con vector de esperanzas $\mathbf{E}(\mathbf{X}_1 | \mathbf{X}_2 = \mathbf{x}_2^0) = \boldsymbol{\mu}_1 + \boldsymbol{\Sigma}_{12} \boldsymbol{\Sigma}_{22}^{-1} (\mathbf{x}_2^0 - \boldsymbol{\mu}_2)$ y matriz de covarianzas $\text{Var}(\mathbf{X}_1 | \mathbf{X}_2 = \mathbf{x}_2^0) = \boldsymbol{\Sigma}_{11} - \boldsymbol{\Sigma}_{12} \boldsymbol{\Sigma}_{22}^{-1} \boldsymbol{\Sigma}_{21}$.

Ejemplo 3.1 Sea $\mathbf{X} = (X_1, X_2, X_3)'$ un vector aleatorio con ley normal de media $\boldsymbol{\mu} = (-1, 1, 0)'$ y matriz de covarianzas

$$\boldsymbol{\Sigma} = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 3 & 1 \\ 1 & 1 & 2 \end{pmatrix}.$$

- a) Encontrar la ley de la v.a. $Y = X_1 + 2X_2 - 3X_3$
- b) Encontrar un vector \mathbf{a} , 2×1 , tal que las v.a. X_1 y $X_1 - \mathbf{a}' \begin{pmatrix} X_2 \\ X_3 \end{pmatrix}$ sean independientes.
- c) Calcular la distribución de X_3 condicionada a $(X_1, X_2)' = (x_1^0, x_2^0)'$.

a) La v.a. $Y = X_1 + 2X_2 - 3X_3$ puede escribirse como $Y = \mathbf{b}'\mathbf{X}$, donde $\mathbf{b} = (1, 2, -3)'$. Puesto que $\mathbf{X} \sim N_3(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, la v.a. Y tendrá ley normal. Su esperanza y varianza son:

$$E(Y) = E(\mathbf{b}'\mathbf{X}) = \mathbf{b}'\boldsymbol{\mu} = (1, 2, -3) \begin{pmatrix} -1 \\ 1 \\ 0 \end{pmatrix} = 1.$$

$$\text{var}(Y) = \text{var}(\mathbf{b}'\mathbf{X}) = \mathbf{b}'\boldsymbol{\Sigma}\mathbf{b} = (1, 2, -3) \begin{pmatrix} 1 & 0 & 1 \\ 0 & 3 & 1 \\ 1 & 1 & 2 \end{pmatrix} \begin{pmatrix} 1 \\ 2 \\ -3 \end{pmatrix} = 13.$$

b) $\mathbf{a} = (a_1, a_2)'$ tal que X_1 y $X_1 - a_1X_2 - a_2X_3$ sean independientes.

Puesto que bajo el supuesto de normalidad, independencia equivale a incorrelación, debemos encontrar aquel vector \mathbf{a} tal que $\text{cov}(X_1, X_1 - a_1X_2 - a_2X_3) = 0$.

Observemos que $X_1 - a_1X_2 - a_2X_3 = (1, -a_1, -a_2)\mathbf{X}$ y $X_1 = (1, 0, 0)\mathbf{X}$, por tanto:

$$0 = \text{cov}(X_1, X_1 - a_1X_2 - a_2X_3) = (1, 0, 0)\boldsymbol{\Sigma} \begin{pmatrix} 1 \\ -a_1 \\ -a_2 \end{pmatrix} = 1 - a_2 \Rightarrow a_2 = 1.$$

Por tanto, cualquier vector $\mathbf{a} = (k, 1)$, $k \in \mathbb{R}$ hace que las variables X_1 y $X_1 - a_1X_2 - a_2X_3$ sean independientes.

c) Distribución de X_3 condicionada a $(X_1, X_2)' = (x_1^0, x_2^0)'$.

$$\mathbf{X} = \begin{pmatrix} X_1 \\ X_2 \\ X_3 \end{pmatrix} \sim N_3(\boldsymbol{\mu}, \boldsymbol{\Sigma}), \text{ donde } \boldsymbol{\mu} = \begin{pmatrix} -1 \\ 1 \\ 0 \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \mu_3 \end{pmatrix} \text{ y}$$

$$\boldsymbol{\Sigma} = \left(\begin{array}{cc|c} 1 & 0 & 1 \\ 0 & 3 & 1 \\ \hline 1 & 1 & 2 \end{array} \right) = \left(\begin{array}{c|c} \boldsymbol{\Sigma}_{(12)(12)} & \boldsymbol{\Sigma}_{(12)3} \\ \hline \boldsymbol{\Sigma}_{3(12)} & \boldsymbol{\Sigma}_{33} \end{array} \right)$$

La distribución de X_3 condicionada a $(X_1, X_2)' = (x_1^0, x_2^0)'$ será normal univariante, de esperanza

$$\begin{aligned} E(X_3 | (X_1, X_2)' = (x_1^0, x_2^0)') &= \mu_3 + \boldsymbol{\Sigma}_{3(12)} \boldsymbol{\Sigma}_{(12)(12)}^{-1} \begin{pmatrix} x_1^0 - \mu_1 \\ x_2^0 - \mu_2 \end{pmatrix} \\ &= 0 + (1, 1) \begin{pmatrix} 1 & 0 \\ 0 & 3 \end{pmatrix}^{-1} \begin{pmatrix} x_1^0 + 1 \\ x_2^0 - 1 \end{pmatrix} = (1, 1) \begin{pmatrix} 1 & 0 \\ 0 & 1/3 \end{pmatrix} \begin{pmatrix} x_1^0 + 1 \\ x_2^0 - 1 \end{pmatrix} \\ &= (1, 1/3) \begin{pmatrix} x_1^0 + 1 \\ x_2^0 - 1 \end{pmatrix} = x_1^0 + 1 + \frac{1}{3}x_2^0 - \frac{1}{3} = x_1^0 + \frac{1}{3}x_2^0 + \frac{2}{3}, \end{aligned}$$

y varianza:

$$\begin{aligned} \text{var}(X_3 | (X_1, X_2)' = (x_1^0, x_2^0)') &= \boldsymbol{\Sigma}_{33} - \boldsymbol{\Sigma}_{3(12)} \boldsymbol{\Sigma}_{(12)(12)}^{-1} \boldsymbol{\Sigma}_{(12)3} \\ &= 2 - (1, 1) \begin{pmatrix} 1 & 0 \\ 0 & 3 \end{pmatrix}^{-1} \begin{pmatrix} 1 \\ 1 \end{pmatrix} = 2 - (1, 1) \begin{pmatrix} 1 & 0 \\ 0 & 1/3 \end{pmatrix} \begin{pmatrix} 1 \\ 1 \end{pmatrix} \\ &= 2 - (1, 1/3) \begin{pmatrix} 1 \\ 1 \end{pmatrix} = 2 - \left(1 + \frac{1}{3}\right) = \frac{2}{3}. \end{aligned}$$

Resumiendo, $X_3 | (X_1, X_2)' = (x_1^0, x_2^0)' \sim N\left(x_1^0 + \frac{1}{3}x_2^0 + \frac{2}{3}, \frac{2}{3}\right)$.

Ejemplo 3.2 Sean $\mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3, \mathbf{X}_4$ vectores aleatorios independientes

con ley $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, donde $\boldsymbol{\mu} = (1, 2)'$ y $\boldsymbol{\Sigma} = \begin{pmatrix} 1 & 0.1 \\ 0.1 & 2 \end{pmatrix}$.

a) Encontrar la ley del vector aleatorio

$$\mathbf{Y} = \frac{1}{4}\mathbf{X}_1 - \frac{1}{4}\mathbf{X}_2 + \frac{1}{4}\mathbf{X}_3 - \frac{1}{4}\mathbf{X}_4.$$

b) Escribir la función de densidad del vector \mathbf{Y} .

c) Calcular la correlación ρ correspondiente a la matriz de covarianzas $\boldsymbol{\Sigma}$. Observar qué cambios se producen en la densidad de \mathbf{Y} al variar el valor de $\rho = \text{corr}(Y_1, Y_2)$.

a) El vector \mathbf{Y} tiene ley normal bivalente con vector de esperanzas

$$\begin{aligned} E(\mathbf{Y}) &= E\left(\frac{1}{4}\mathbf{X}_1 - \frac{1}{4}\mathbf{X}_2 + \frac{1}{4}\mathbf{X}_3 - \frac{1}{4}\mathbf{X}_4\right) \\ &= \frac{1}{4}E(\mathbf{X}_1) - \frac{1}{4}E(\mathbf{X}_2) + \frac{1}{4}E(\mathbf{X}_3) - \frac{1}{4}E(\mathbf{X}_4) \\ &= \left(\frac{1}{4} - \frac{1}{4} + \frac{1}{4} - \frac{1}{4}\right)\boldsymbol{\mu} = 0 \begin{pmatrix} 1 \\ 2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \end{aligned}$$

y matriz de covarianzas

$$\begin{aligned} \text{Var}(\mathbf{Y}) &= \text{Var}\left(\frac{1}{4}\mathbf{X}_1 - \frac{1}{4}\mathbf{X}_2 + \frac{1}{4}\mathbf{X}_3 - \frac{1}{4}\mathbf{X}_4\right) \\ &= \frac{1}{16}\text{Var}(\mathbf{X}_1) + \frac{1}{16}\text{Var}(\mathbf{X}_2) + \frac{1}{16}\text{Var}(\mathbf{X}_3) + \frac{1}{16}\text{Var}(\mathbf{X}_4) \\ &= \frac{4}{16}\boldsymbol{\Sigma} = \frac{1}{4}\boldsymbol{\Sigma}. \end{aligned}$$

Resumiendo, $\mathbf{Y} \sim N_2\left(\vec{0}, \frac{1}{4}\boldsymbol{\Sigma}\right)$.

b) Puesto que $E(\vec{0})$, la función de densidad de $\mathbf{Y} = (Y_1, Y_2)'$ en el punto $\mathbf{y} = (y_1, y_2)' \in \mathbb{R}^2$ es

$$\begin{aligned} f(\mathbf{y}) &= \frac{|\frac{1}{4}\boldsymbol{\Sigma}|^{-1/2}}{(2\pi)^{2/2}} \exp\left\{-\frac{1}{2}\mathbf{y}'\left(\frac{1}{4}\boldsymbol{\Sigma}\right)^{-1}\mathbf{y}\right\} \\ &= \frac{1}{\pi|\boldsymbol{\Sigma}|^{1/2}} \exp\{2\mathbf{y}'\boldsymbol{\Sigma}^{-1}\mathbf{y}\}, \quad \mathbf{y} \in \mathbb{R}^2. \end{aligned}$$

c) La matriz de covarianzas de \mathbf{Y} es $\boldsymbol{\Sigma} = \begin{pmatrix} 1 & 0.1 \\ 0.1 & 2 \end{pmatrix}$. Por tanto, el coeficiente de correlación será $\rho = \text{corr}(Y_1, Y_2) = \frac{\sigma_{12}}{\sigma_1\sigma_2} = \frac{0.1}{\sqrt{1 \cdot 2}} \approx 0.071$.

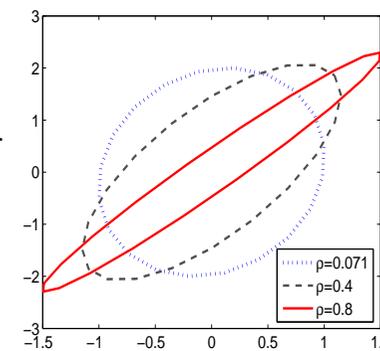
¿Cómo influye el valor de ρ en la densidad de \mathbf{Y} ?

Puesto que $\sigma_{12} = \sigma_1\sigma_2\rho$, la matriz $\boldsymbol{\Sigma}$ puede escribirse en función de ρ como $\boldsymbol{\Sigma} = \begin{pmatrix} 1 & \sqrt{2}\rho \\ \sqrt{2}\rho & 2 \end{pmatrix}$.

En el Tema 2 vimos dos medidas de dispersión global:

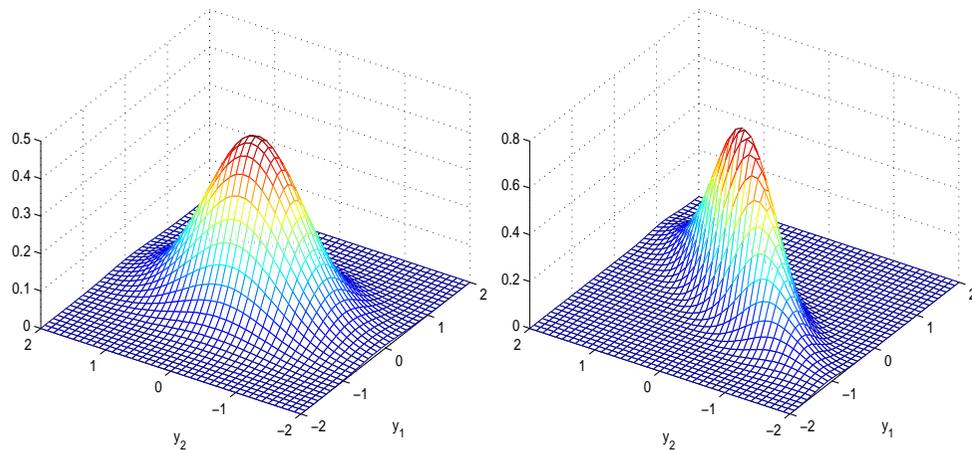
- La variación total $\text{tr}(\boldsymbol{\Sigma}) = 3$, que no depende de ρ .
- La varianza generalizada $\det(\boldsymbol{\Sigma}) = 2(1 - \rho^2)$.
 $\rho^2 = 0 \Rightarrow \det(\boldsymbol{\Sigma}) = 2$
 $\rho^2 = 1 \Rightarrow \det(\boldsymbol{\Sigma}) = 0$.

A medida que ρ aumenta, la dispersión global disminuye.



Elipses de la forma cuadrática $\mathbf{y}\boldsymbol{\Sigma}^{-1}\mathbf{y}'$

Función de densidad de $\mathbf{Y} \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, $\boldsymbol{\mu} = (0, 0)'$ y $\boldsymbol{\Sigma} = \begin{pmatrix} 1 & \sqrt{2}\rho \\ \sqrt{2}\rho & 2 \end{pmatrix}$.



(a) $\rho = 0.071$

(b) $\rho = 0.8$

3.3 Distribuciones relacionadas con la normal multivariante

En esta sección consideraremos distribuciones asociadas a una muestra de tamaño n de una vector aleatorio normal p -variante.

Paralelismos entre el caso univariante y el multivariante:

Caso univariante	Caso multivariante
$N(\mu, \sigma^2)$	$N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$
χ_n^2	$W_p(\boldsymbol{\Sigma}, n)$
$F(m, n)$	$\Lambda(p, a, b)$
t	T^2

La ley Wishart

Dada una muestra aleatoria simple de tamaño n de una ley $N_p(\vec{0}, \boldsymbol{\Sigma})$ (es decir, $\mathbf{X}_1, \dots, \mathbf{X}_n$ sucesión de vectores aleatorios $\text{iid} \sim N_p(\vec{0}, \boldsymbol{\Sigma})$), se define la distribución de Wishart como la ley de la matriz aleatoria, $p \times p$,

$$\mathbf{Q} = \sum_{i=1}^n \mathbf{X}_i \mathbf{X}_i' \sim W_p(\boldsymbol{\Sigma}, n)$$

Propiedades:

- $Q_1 \sim W_p(\boldsymbol{\Sigma}, n_1)$, $Q_2 \sim W_p(\boldsymbol{\Sigma}, n_2)$ independientes, entonces $Q_1 + Q_2 \sim W_p(\boldsymbol{\Sigma}, n_1 + n_2)$.
- (Teorema de Fisher) Si \mathbf{S} es la matriz de covarianzas de una muestra de tamaño n obtenida a partir de un vector con ley $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, entonces:
 - El vector $\bar{\mathbf{x}}$ y la matriz \mathbf{S} son estocásticamente independientes,
 - $\bar{\mathbf{x}} \sim N_p(\boldsymbol{\mu}, \frac{1}{n}\boldsymbol{\Sigma})$,
 - $n\mathbf{S} \sim W_p(\boldsymbol{\Sigma}, n - 1)$.

La ley Lambda de Wilks

La distribución Lambda de Wilks es la ley del cociente de determinantes

$$\Lambda = \frac{|\mathbf{A}|}{|\mathbf{A} + \mathbf{B}|} \sim \Lambda(p, a, b),$$

donde $\mathbf{A} \sim W_p(\boldsymbol{\Sigma}, a)$, $\mathbf{B} \sim W_p(\boldsymbol{\Sigma}, b)$, independientes, siendo $\boldsymbol{\Sigma}$ no singular y $a \geq p$.

Propiedades:

- $\Lambda(p, a, b) = \Lambda(b, a + b - p, p)$.
- En general, una transformación de Λ equivale, exacta o asintóticamente, a una F de Fisher. Por ejemplo:
 - si $p = 1$, $\frac{1-\Lambda}{\Lambda} \frac{a}{b} = F(b, a)$,
 - si $p = 2$, $\frac{1-\Lambda^{1/2}}{\Lambda^{1/2}} \frac{a-1}{b} = F(2b, 2(a-1))$.

La ley T^2 de Hotelling

Se define la distribución T^2 de Hotelling como la ley de la v.a.

$$T^2 = n \mathbf{Z}' \mathbf{Q}^{-1} \mathbf{Z} \sim T^2(p, n),$$

donde $\mathbf{Z} \sim N_p(\vec{0}, \mathbf{I})$, $\mathbf{Q} \sim W_p(\mathbf{I}, n)$ estocásticamente independientes.

Propiedades:

1. Si $p = 1$, $T^2(1, n)$ es el cuadrado de una v.a. con ley t de Student con n grados de libertad.
2. En general, $T^2(p, n)$ es proporcional a una F de Fisher, es decir, $\frac{n-p+1}{n p} T^2(p, n) = F(p, n-p+1)$.
3. Transformaciones afines sobre \mathbf{Z} no afectan a la ley T^2 . Es decir, si $\mathbf{X} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, $\mathbf{R} \sim W_p(\boldsymbol{\Sigma}, n)$ independientes, entonces $n(\mathbf{X} - \boldsymbol{\mu})' \mathbf{R}^{-1} (\mathbf{X} - \boldsymbol{\mu}) \sim T^2(p, n)$.

4. Si $\mathbf{X}_1, \dots, \mathbf{X}_n$ es una muestra aleatoria simple de una ley $N_p(\vec{0}, \boldsymbol{\Sigma})$, entonces:

$$(n-1)(\bar{\mathbf{x}} - \boldsymbol{\mu})' \mathbf{S}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}) = n(\bar{\mathbf{x}} - \boldsymbol{\mu})' \tilde{\mathbf{S}}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}) \sim T^2(p, n-1).$$

5. Dadas dos muestras aleatorias simples e independientes, $\mathbf{X}_1, \dots, \mathbf{X}_{n_1}$ iid $\sim N_p(\boldsymbol{\mu}_1, \boldsymbol{\Sigma})$, $\mathbf{Y}_1, \dots, \mathbf{Y}_{n_2}$ iid $\sim N_p(\boldsymbol{\mu}_2, \boldsymbol{\Sigma})$, si $\boldsymbol{\mu}_1 = \boldsymbol{\mu}_2$, entonces:

$$\frac{n_1 n_2}{n_1 + n_2} (\bar{\mathbf{x}} - \bar{\mathbf{y}})' \mathbf{S}_P^{-1} (\bar{\mathbf{x}} - \bar{\mathbf{y}}) \sim T^2(p, n_1 + n_2 - 2),$$

donde $\mathbf{S}_P = \frac{1}{n_1 + n_2} (n_1 \mathbf{S}_1 + n_2 \mathbf{S}_2)$ es la media aritmética ponderada de las matrices de covarianzas muestrales (*pooled covariance matrix*).

Observación 4 Las propiedades 4 y 5 nos dicen que la ley T^2 de Hotelling se utilizará en los contrastes multivariantes sobre medias, de forma análoga a la ley t de Student en el caso univariante.

3.4 Aplicaciones a la inferencia multivariante

[1]. Sea \mathcal{X} una matriz de datos $n \times p$, cuyas filas representan una muestra aleatoria simple de una ley $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$. Consideremos el siguiente contraste de hipótesis:

$$H_0 : \boldsymbol{\mu} = \boldsymbol{\mu}_0, \quad \boldsymbol{\mu}_0 \in \mathbb{R}^p.$$

Cuando H_0 sea cierta, el estadístico

$$(n-1)(\bar{\mathbf{x}} - \boldsymbol{\mu}_0)' \mathbf{S}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}_0) \sim T^2(p, n-1).$$

Utilizando la propiedad 2 de la ley T^2 de Hotelling, tendremos que

$$\frac{n-p}{p} (\bar{\mathbf{x}} - \boldsymbol{\mu}_0)' \mathbf{S}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}_0) \sim F(p, n-p)$$

y podremos obtener una región crítica para el nivel de significación deseado.

[2]. Consideremos dos matrices de datos \mathcal{X} e \mathcal{Y} : \mathcal{X} , $n_1 \times p$, provienen de una ley $N_p(\boldsymbol{\mu}_1, \boldsymbol{\Sigma})$, \mathcal{Y} , $n_2 \times p$, provienen de una ley $N_p(\boldsymbol{\mu}_2, \boldsymbol{\Sigma})$ independientes.

Consideremos el siguiente contraste de hipótesis:

$$H_0 : \boldsymbol{\mu}_1 = \boldsymbol{\mu}_2.$$

Cuando H_0 sea cierta, el estadístico

$$\frac{n_1 n_2}{n_1 + n_2} (\bar{\mathbf{x}} - \bar{\mathbf{y}})' \mathbf{S}_P^{-1} (\bar{\mathbf{x}} - \bar{\mathbf{y}}) \sim T^2(p, n_1 + n_2 - 2),$$

donde $\mathbf{S}_P = \frac{1}{n_1 + n_2} (n_1 \mathbf{S}_1 + n_2 \mathbf{S}_2)$. De forma equivalente (utilizando la propiedad 2 de la ley T^2 de Hotelling), el estadístico

$$\frac{n_1 + n_2 - p - 1}{(n_1 + n_2 - 2)p} \frac{n_1 n_2}{n_1 + n_2} (\bar{\mathbf{x}} - \bar{\mathbf{y}})' \mathbf{S}_P^{-1} (\bar{\mathbf{x}} - \bar{\mathbf{y}}) \sim F(p, n_1 + n_2 - p - 1)$$

y podremos obtener una región crítica para el nivel de significación deseado.

[3]. Supongamos que tenemos g matrices de datos provenientes de g distribuciones normales multivariantes independientes:

muestra	tamaño matriz	media (muestral)	covarianza (muestral)	ley de probabilidad
\mathcal{X}_1	$n_1 \times p$	$\bar{\mathbf{x}}_1$	\mathbf{S}_1	$N_p(\boldsymbol{\mu}_1, \boldsymbol{\Sigma})$
\mathcal{X}_2	$n_2 \times p$	$\bar{\mathbf{x}}_2$	\mathbf{S}_2	$N_p(\boldsymbol{\mu}_2, \boldsymbol{\Sigma})$
\vdots	\vdots	\vdots	\vdots	\vdots
\mathcal{X}_g	$n_g \times p$	$\bar{\mathbf{x}}_g$	\mathbf{S}_g	$N_p(\boldsymbol{\mu}_g, \boldsymbol{\Sigma})$

La estimación muestral del vector de medias global y la matriz de covarianzas común son

$$\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^g n_i \bar{\mathbf{x}}_i, \quad \mathbf{S} = \frac{1}{n-g} \sum_{i=1}^g n_i \mathbf{S}_i, \quad \text{siendo } n = \sum_{i=1}^g n_i.$$

Queremos contraste de hipótesis $H_0 : \boldsymbol{\mu}_1 = \boldsymbol{\mu}_2 = \dots = \boldsymbol{\mu}_g$.

Para ello, introducimos las siguientes matrices:

$$\mathbf{B} = \sum_{i=1}^g n_i (\bar{\mathbf{x}}_i - \bar{\mathbf{x}})(\bar{\mathbf{x}}_i - \bar{\mathbf{x}})', \quad (\text{dispersión entre grupos})$$

$$\mathbf{W} = \sum_{i=1}^g \sum_{k=1}^{n_i} (x_{ik} - \bar{\mathbf{x}}_i)(x_{ik} - \bar{\mathbf{x}}_i)' = \sum_{i=1}^g n_i \mathbf{S}_i, \quad (\text{dispersión dentro de los grupos})$$

$$\mathbf{T} = \mathbf{B} + \mathbf{W}, \quad (\text{dispersión total}).$$

Si H_0 es cierta, $\mathbf{B} \sim W_p(\boldsymbol{\Sigma}, g-1)$, $\mathbf{W} \sim W_p(\boldsymbol{\Sigma}, n-g)$ son independientes y $\mathbf{T} \sim W_p(\boldsymbol{\Sigma}, n-1)$. Para resolver este contraste utilizaremos el estadístico:

$$\Lambda = \frac{|\mathbf{W}|}{|\mathbf{W} + \mathbf{B}|} \sim \Lambda(p, n-g, g-1),$$

que se aproxima a una ley F de Fisher mediante la *aproximación asintótica de Rao*:

$$\text{Si } \Lambda \sim \Lambda(p, a, b), \text{ entonces } \frac{1 - \Lambda^{1/\beta}}{\Lambda^{1/\beta}} \frac{\alpha\beta - 2\gamma}{pb} \sim F(pb, \alpha\beta - 2\gamma),$$

donde $\alpha = a + b - (p + b + 1)/2$, $\beta^2 = (p^2 b^2 - 4)/(p^2 + b^2 - 5)$, $\gamma = (pb - 2)/4$.

Ejemplo 3.3 Un psicólogo realiza dos tests, uno de capacidad verbal (variable X_1) y otro de rendimiento intelectual general (variable X_2), a $n = 101$ individuos adultos, obteniendo los siguientes resultados:

$$\bar{\mathbf{x}} = (55.24, 34.97)', \quad \mathbf{S} = \begin{pmatrix} 210.54 & 126.99 \\ 126.99 & 119.68 \end{pmatrix}$$

Contrastar la hipótesis de que la media poblacional es $\boldsymbol{\mu} = (60, 40)'$.

Se trata de un contraste para la media poblacional $H_0 : \boldsymbol{\mu} = \boldsymbol{\mu}_0$, donde $\boldsymbol{\mu}_0 = (60, 40)'$, $n = 101$, $p = 2$. Por tanto, utilizaremos el estadístico T^2 de Hotelling

$$T^2 = (n-1)(\bar{\mathbf{x}} - \boldsymbol{\mu}_0)' \mathbf{S}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}_0) \sim T^2(p, n-1),$$

o, equivalentemente,

$$F = \frac{n-p}{p} (\bar{\mathbf{x}} - \boldsymbol{\mu}_0)' \mathbf{S}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}_0) \sim F(p, n-p).$$

Mediante Matlab, obtenemos $F = 10.68 > F_{(2,99)}^{0.05} = 3.07$. Por tanto, se rechaza H_0 , es decir, $\boldsymbol{\mu} \neq (60, 40)'$

Ejercicios computacionales

Ejercicio 3.1 Generar dos muestras de tamaños $n_1 = 100$ y $n_2 = 150$ provenientes, respectivamente, de dos leyes normales multivariantes $N_3(\boldsymbol{\mu}_1, \boldsymbol{\Sigma})$ y $N_3(\boldsymbol{\mu}_2, \boldsymbol{\Sigma})$, con

$$\boldsymbol{\mu}_1 = (1, 0, 1)', \quad \boldsymbol{\mu}_2 = (0.9, 0.01, 1)' \quad \text{y} \quad \boldsymbol{\Sigma} = \begin{pmatrix} 2 & 1 & 1 \\ 1 & 1 & 0 \\ 1 & 0 & 2 \end{pmatrix}$$

- Obtener los vectores de medias y las matrices de covarianzas muestrales.
- Contrastar la hipótesis $H_0 : \boldsymbol{\mu}_1 = (1, 0, 1)'$ vs. $H_1 : \boldsymbol{\mu}_1 \neq (1, 0, 1)'$.
- Contrastar las hipótesis $H_0 : \boldsymbol{\mu}_1 = \boldsymbol{\mu}_2$ vs. $H_1 : \boldsymbol{\mu}_1 \neq \boldsymbol{\mu}_2$, mediante el contraste de la T^2 de Hotelling y mediante el contraste de la Lambda de Wilks.