

Distribuciones multivariantes

Mathias Bourel

IMERL - Facultad de Ingeniería, Universidad de la República, Uruguay

23 de abril de 2019

Plan

- 1 Distribuciones multivariantes
- 2 Distribución multinomial
- 3 Normal Multivariada
- 4 Distribuciones mezcladas

Plan

- 1 Distribuciones multivariantes
- 2 Distribución multinomial
- 3 Normal Multivariada
- 4 Distribuciones mezcladas

Distribución conjunta de una variable aleatoria vectorial

Sea $\mathbf{x} = (x_1, \dots, x_p) \in \mathbb{R}^p$ una VA vectorial.

Función de distribución:

$$F_{\mathbf{x}}(x^0) = \mathbb{P}(\mathbf{x} \leq x^0) = \mathbb{P}(x_1 \leq x_1^0, x_2 \leq x_2^0, \dots, x_p \leq x_p^0)$$

- Si \mathbf{x} es discreta, entonces $p(x^0) = \mathbb{P}(\mathbf{x} = x^0) = \mathbb{P}(x_1 = x_1^0, x_2 = x_2^0, \dots, x_p = x_p^0)$
- Decimos que \mathbf{x} es absolutamente continua, si existe una función $f : \mathbb{R}^p \rightarrow \mathbb{R}$ no negativa con $\int_{\mathbb{R}^p} f(\mathbf{x}) d\mathbf{x} = 1$ tal que

$$F_{\mathbf{x}}(x^0) = \int_{-\infty}^{x^0} f(\mathbf{x}) d\mathbf{x} = \int_{-\infty}^{x_1^0} \int_{-\infty}^{x_2^0} \dots \int_{-\infty}^{x_p^0} f(x_1, \dots, x_p) dx_1 dx_2 \dots dx_p$$

Si x es escalar y absolutamente continua, entonces

$$p(x^0) = \mathbb{P}\left(x \in \left[x^0 - \frac{\Delta x}{2}, x^0 + \frac{\Delta x}{2}\right]\right) = \int_{x^0 - \frac{\Delta x}{2}}^{x^0 + \frac{\Delta x}{2}} f(t) dt \approx f(x^0)\Delta x$$

En general si \mathbf{x} es vectorial $p(x^0) = f(x^0)\Delta \mathbf{x}$, siendo $\Delta \mathbf{x}$ el elemento de volumen.

Distribuciones marginales y condicionadas

DISTRIBUCIONES MARGINALES:

- $\mathbf{x} = (x_1, x_2) \in \mathbb{R}^2$ con distribución conjunta f_{x_1, x_2} entonces

$$f_{x_1}(x_1) = \int_{\mathbb{R}} f_{x_1, x_2}(x_1, x_2) dx_2 \quad f_{x_2}(x_2) = \int_{\mathbb{R}} f_{x_1, x_2}(x_1, x_2) dx_1$$

y con abuso de notación:

$$f(x_1) = \int_{\mathbb{R}} f(x_1, x_2) dx_2 \quad f(x_2) = \int_{\mathbb{R}} f(x_1, x_2) dx_1$$

- $\int_{\mathbb{R}} f_{x_1}(x_1) dx_1 = \int_{\mathbb{R}} f_{x_2}(x_2) dx_2 = 1$

Distribuciones marginales y condicionadas

DISTRIBUCIONES CONDICIONADAS:

- Sea el vector aleatorio $X = (\mathbf{x}_1, \mathbf{x}_2) \in \mathbb{R}^{p \times 2}$.

Definimos la distribución condicionada de \mathbf{x}_1 para un valor de $\mathbf{x}_2 = \mathbf{x}_2^0$ como

$$f(\mathbf{x}_1 | \mathbf{x}_2 = \mathbf{x}_2^0) = \frac{f(\mathbf{x}_1, \mathbf{x}_2^0)}{f(\mathbf{x}_2^0)} \quad \text{suponiendo que } f(\mathbf{x}_2^0) \neq 0$$

Esto es consistente con el concepto de probabilidad condicionada, pues, suponiendo que las variables \mathbf{x}_1 y \mathbf{x}_2 son escalares

$$\underbrace{f(x_1 | x_2^0) \Delta x_1}_{P(x_1 | x_2^0)} = \underbrace{\frac{f(x_1, x_2^0) \Delta x_1 \Delta x_2}{f(x_2^0) \Delta x_2}}_{\frac{P(x_1, x_2^0)}{P(x_2^0)}}$$

Entonces

$$f(\mathbf{x}_1, \mathbf{x}_2) = f(\mathbf{x}_1 | \mathbf{x}_2) f(\mathbf{x}_2) \quad f(\mathbf{x}_1, \mathbf{x}_2) = f(\mathbf{x}_2 | \mathbf{x}_1) f(\mathbf{x}_1)$$

Distribuciones marginales y condicionadas

La distribución marginal de \mathbf{x}_2 se puede calcular como

$$f(\mathbf{x}_2) = \int f(\mathbf{x}_2|\mathbf{x}_1)f(\mathbf{x}_1)d\mathbf{x}_1$$

Observar que si multiplicamos por $\Delta\mathbf{x}_2$ esto se puede interpretar como

$$f(\mathbf{x}_2)\Delta\mathbf{x}_2 = \int f(\mathbf{x}_2|\mathbf{x}_1)f(\mathbf{x}_1)d\mathbf{x}_1\Delta\mathbf{x}_2$$

$$p(\mathbf{x}_2) = \sum \underbrace{f(\mathbf{x}_2|\mathbf{x}_1)\Delta\mathbf{x}_2}_{p(\mathbf{x}_2|\mathbf{x}_1)} \underbrace{f(\mathbf{x}_1)\Delta\mathbf{x}_1}_{p(\mathbf{x}_1)}$$

FORMULA DE BAYES:

$$f(\mathbf{x}_1|\mathbf{x}_2) = \frac{f(\mathbf{x}_2|\mathbf{x}_1)f(\mathbf{x}_1)}{f(\mathbf{x}_2)} = \frac{f(\mathbf{x}_2|\mathbf{x}_1)f(\mathbf{x}_1)}{\int f(\mathbf{x}_2|\mathbf{x}_1)f(\mathbf{x}_1)d\mathbf{x}_1}$$

Ejemplo

x_1 votar a algún candidato c_1, c_2, c_3, c_4 y x_2 nivel de ingreso A (alto), M (medio), B (bajo).
Presentamos la distribución conjunta de votos:

	A	M	B
c_1	.1	.05	.01
c_2	.05	.20	.04
c_3	.04	.25	.07
c_4	.01	.1	.08

Distribuciones marginales:

	A	M	B	votos
c_1	.1	.05	.01	0.16
c_2	.05	.20	.04	0.29
c_3	.04	.25	.07	0.36
c_4	.01	.1	.08	0.19
ingresos	0.2	0.6	0.2	

Ejemplo

Distribución condicionada de los votos por personas con nivel de ingreso B:

	c_1	c_2	c_3	c_4
B	$\frac{0,01}{0,2} = 0,05$	$\frac{0,04}{0,2} = 0,2$	$\frac{0,07}{0,2} = 0,35$	$\frac{0,08}{0,2} = 0,4$

Distribución condicionada de los ingresos por votantes del candidato c_4 :

	A	M	B
c_4	$\frac{0,01}{0,19} = 0,0526$	$\frac{0,1}{0,19} = 0,5263$	$\frac{0,08}{0,19} = 0,4211$

Independencia de vectores aleatorios

\mathbf{x}_1 y \mathbf{x}_2 son **independientes** si

$$f(\mathbf{x}_2|\mathbf{x}_1) = f(\mathbf{x}_2)$$

lo cual equivale a

$$f(\mathbf{x}_1, \mathbf{x}_2) = f(\mathbf{x}_1)f(\mathbf{x}_2)$$

Notación: $\mathbf{x}_1 \perp \mathbf{x}_2$

Observación: si $\mathbf{x}_1 \perp \mathbf{x}_2$ entonces $g_1(\mathbf{x}_1) = \mathbf{y}_1 \perp \mathbf{y}_2 = g_2(\mathbf{x}_2)$

Vector de medias

Sea $\mathbf{x} = (x_1, \dots, x_p)$ una VA en \mathbb{R}^p . El vector de medias es

$$\mathbb{E}(\mathbf{x}) = \boldsymbol{\mu} = \begin{pmatrix} \mu_1 \\ \vdots \\ \mu_p \end{pmatrix} = \begin{pmatrix} \mathbb{E}(x_1) \\ \vdots \\ \mathbb{E}(x_p) \end{pmatrix}$$

Si \mathbf{x} es continua entonces notamos $\mathbb{E}(\mathbf{x}) = \int \mathbf{x}f(\mathbf{x}), d\mathbf{x}$ donde $\mathbb{E}(x_i) = \int x f_{x_i}(x) dx \forall i$

Proposición 1

- $\mathbb{E}(A\mathbf{x} + \mathbf{b}) = A\mathbb{E}(\mathbf{x}) + \mathbf{b}$ siendo A una matriz y \mathbf{b} un vector.
- Si $\mathbf{x} = (x_1, x_2)$ y $a, b \in \mathbb{R}$ entonces $\mathbb{E}(ax_1 + bx_2) = a\mathbb{E}(x_1) + b\mathbb{E}(x_2)$

Matriz de varianzas y covarianzas

Sea $\mathbf{x} = (x_1, \dots, x_p)$ una VA en \mathbb{R}^p . Su matriz de varianzas y covarianzas es la matriz cuadrada

$$\text{Var}(\mathbf{x}) = V_x = \mathbb{E}[(\mathbf{x} - \mu)(\mathbf{x} - \mu)'] \in \mathcal{M}_{p \times p}$$

$$V_x = \begin{pmatrix} \sigma_1^2 & s_{12} & \cdots & s_{1p} \\ s_{12} & \sigma_2^2 & \cdots & s_{2p} \\ \vdots & & \ddots & \vdots \\ s_{1p} & s_{2p} & \cdots & \sigma_p^2 \end{pmatrix}$$

siendo

$$\sigma_i^2 = \text{Var}(x_i), \quad s_{ij} = \text{Cov}(x_i, x_j) = \mathbb{E}(x_i x_j) - \mathbb{E}(x_i)\mathbb{E}(x_j)$$

Matriz de varianzas y covarianzas

Propiedades:

- 1 V_x es simétrica (es claro)
- 2 V_x es semidefinida positiva, es decir para todo $\mathbf{w} \in \mathbb{R}^p$ se tiene que $\mathbf{w}' V_x \mathbf{w} \geq 0$.
En efecto, sea $\mathbf{w} \in \mathbb{R}^p$ y defino $y = (\mathbf{x} - \boldsymbol{\mu})' \mathbf{w} \in \mathbb{R}$. Entonces

$$\mathbb{E}(y) = \mathbb{E}((\mathbf{x} - \boldsymbol{\mu})' \mathbf{w}) = \mathbb{E}((\mathbf{x} - \boldsymbol{\mu}))' \mathbf{w} = 0$$

Por lo tanto

$$\text{Var}(y) = \mathbb{E}(y^2) = \mathbf{w}' \mathbb{E}((\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})') \mathbf{w} = \mathbf{w}' V_x \mathbf{w} \geq 0$$

Transformación de vectores aleatorios

Sea $\mathbf{x} = (x_1, \dots, x_p)$ un vector aleatorio de \mathbb{R}^p con densidad $f_x(\mathbf{x})$ y sea otro vector aleatorio $\mathbf{y} = (y_1, \dots, y_p) \in \mathbb{R}^p$ definido por

$$\begin{cases} y_1 = g_1(x_1, \dots, x_p) \\ y_2 = g_2(x_1, \dots, x_p) \\ \vdots \\ y_p = g_p(x_1, \dots, x_p) \end{cases}$$

donde suponemos que existen las funciones inversas $x_1 = h_1(y_1, \dots, y_p), \dots, x_p = h_p(y_1, \dots, y_p)$, siendo $g_1, \dots, g_p, h_1, \dots, h_p$ diferenciables.

Entonces puede demostrarse (regla del Jacobiano) que:

$$f_y(\mathbf{y}) = f_x(\mathbf{x}) \left| \det \begin{pmatrix} \frac{\partial x_1}{\partial y_1} & \cdots & \cdots & \frac{\partial x_1}{\partial y_p} \\ \vdots & & & \vdots \\ \frac{\partial x_p}{\partial y_1} & \cdots & \cdots & \frac{\partial x_p}{\partial y_p} \end{pmatrix} \right|$$

Caso particular. Supongamos que $\mathbf{y} = A\mathbf{x}$ siendo $A \in \mathcal{M}_{p \times p}$ invertible. Entonces

$$f_y(\mathbf{y}) = f_x(A^{-1}\mathbf{y}) |\det(A^{-1})|$$

Esperanza y varianza de transformaciones lineales

Supongamos que $\mathbf{y} = A\mathbf{x}$ siendo $A \in \mathcal{M}_{p \times p}$. Entonces

Proposición 2

- 1 $\mu_{\mathbf{y}} = A\mu_{\mathbf{x}}$
- 2 $V_{\mathbf{y}} = AV_{\mathbf{x}}A'$

Demostración.

- 1 Ya lo vimos.
- 2
$$\begin{aligned} V_{\mathbf{y}} &= \mathbb{E}((\mathbf{y} - \mu_{\mathbf{y}})(\mathbf{y} - \mu_{\mathbf{y}})') \\ &= \mathbb{E}(A(\mathbf{x} - \mu_{\mathbf{x}})(\mathbf{x} - \mu_{\mathbf{x}})'A') = A\mathbb{E}((\mathbf{x} - \mu_{\mathbf{x}})(\mathbf{x} - \mu_{\mathbf{x}})')A' = AV_{\mathbf{x}}A' \end{aligned}$$



Esperanza condicionada

La esperanza de \mathbf{x}_1 condicionada a \mathbf{x}_2 es:

$$\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2) = \int \mathbf{x}_1 f(\mathbf{x}_1|\mathbf{x}_2) d\mathbf{x}_1$$

y es una función de \mathbf{x}_2 .

Si \mathbf{x}_2 es un valor fijo entonces $\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2)$ es constante.

Si \mathbf{x}_2 es un variable aleatoria entonces $\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2)$ es una variable aleatoria.

Proposición 3

Se cumple que

$$\mathbb{E}(\mathbf{x}_1) = \mathbb{E}(\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2))$$

y la esperanza de la media condicionada es la esperanza marginal

Demostración:

$$\begin{aligned}\mathbb{E}(\mathbf{x}_1) &= \int \mathbf{x}_1 f(\mathbf{x}_1) d\mathbf{x}_1 = \int \mathbf{x}_1 \left(\int f(\mathbf{x}_1|\mathbf{x}_2) f(\mathbf{x}_2) d\mathbf{x}_2 \right) d\mathbf{x}_1 \\ &= \int \int \mathbf{x}_1 f(\mathbf{x}_1|\mathbf{x}_2) f(\mathbf{x}_2) d\mathbf{x}_1 d\mathbf{x}_2 = \int f(\mathbf{x}_2) \left(\int \mathbf{x}_1 f(\mathbf{x}_1|\mathbf{x}_2) d\mathbf{x}_1 \right) d\mathbf{x}_2 \\ &= \int f(\mathbf{x}_2) \mathbb{E}(\mathbf{x}_1|\mathbf{x}_2) d\mathbf{x}_2 = \mathbb{E}(\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2))\end{aligned}$$

Varianza condicionada

$$\text{Var}(\mathbf{x}_1|\mathbf{x}_2) = \mathbb{E}[(\mathbf{x}_1 - \mathbb{E}(\mathbf{x}_1|\mathbf{x}_2))^2|\mathbf{x}_2]$$

Propiedad

$$\text{Var}(\mathbf{x}_1|\mathbf{x}_2) = \mathbb{E}(\mathbf{x}_1^2|\mathbf{x}_2) - (\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2))^2$$

Lo verificamos para cada y :

$$\begin{aligned}\text{Var}(\mathbf{x}_1|\mathbf{x}_2 = y) &= \mathbb{E}[(\mathbf{x}_1 - \mathbb{E}(\mathbf{x}_1|\mathbf{x}_2 = y))^2|\mathbf{x}_2 = y] \\ &= \mathbb{E}[\mathbf{x}_1^2 + (\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2 = y))^2 - 2\mathbf{x}_1\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2 = y)|\mathbf{x}_2 = y]\end{aligned}$$

Como $\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2 = y)$ es una constante cuando se considera la distribución condicionada a $\mathbf{x}_2 = y$, el resultado lo deducimos de la linealidad de la esperanza condicionada.

Descomposición de la varianza

$$\text{Var}(\mathbf{x}_1) = \text{Var}(\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2)) + \mathbb{E}(\text{Var}(\mathbf{x}_1|\mathbf{x}_2))$$

Se sabe que $\mathbb{E}(\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2)) = \mathbb{E}(\mathbf{x}_1)$ y $\mathbb{E}(\mathbb{E}(\mathbf{x}_1^2|\mathbf{x}_2)) = \mathbb{E}(\mathbf{x}_1^2)$. Entonces:

$$\begin{aligned}\text{Var}(\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2)) + \mathbb{E}(\text{Var}(\mathbf{x}_1|\mathbf{x}_2)) &= \mathbb{E}[(\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2))^2] - [\mathbb{E}(\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2))]^2 + \mathbb{E}(\mathbb{E}(\mathbf{x}_1^2|\mathbf{x}_2)) - \mathbb{E}[(\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2))^2] \\ &= \mathbb{E}[(\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2))^2] - [\mathbb{E}(\mathbf{x}_1)]^2 + \mathbb{E}(\mathbf{x}_1^2) - \mathbb{E}[(\mathbb{E}(\mathbf{x}_1|\mathbf{x}_2))^2] = \text{Var}(\mathbf{x}_1).\end{aligned}$$

Descomposición de la varianza

En particular, si x_1 es una variable aleatoria real y $\mathbb{E}(x_1) = \mu_1$ entonces:

- (A) : $\mathbb{E}((x_1 - \mu_1)^2) = \text{Var}(x_1)$
- (B) : como $\mu_1 = \mathbb{E}(\mathbb{E}(x_1|\mathbf{x}_2))$ entonces $\text{Var}(\mathbb{E}(x_1|\mathbf{x}_2)) = \mathbb{E}((\mathbb{E}(x_1|\mathbf{x}_2) - \mu_1)^2)$
- (C) : como $\text{Var}(x_1|\mathbf{x}_2) = \mathbb{E}((x_1 - \mathbb{E}(x_1|\mathbf{x}_2))^2|\mathbf{x}_2)$ entonces $\mathbb{E}(\text{Var}(x_1|\mathbf{x}_2)) = \mathbb{E}((x_1 - \mathbb{E}(x_1|\mathbf{x}_2))^2)$

Por lo tanto de

$$\text{Var}(x_1) = \mathbb{E}(\text{Var}(x_1|\mathbf{x}_2)) + \text{Var}(\mathbb{E}(x_1|\mathbf{x}_2))$$

se deduce que:

$$\underbrace{\mathbb{E}((x_1 - \mu_1)^2)}_{(A)} = \underbrace{\mathbb{E}((\mathbb{E}(x_1|\mathbf{x}_2) - \mu_1)^2)}_{(B)} + \underbrace{\mathbb{E}((x_1 - \mathbb{E}(x_1|\mathbf{x}_2))^2)}_{(C)}$$

El segundo termino promedia las varianzas de las distribuciones condicionadas. El primer termino recoge las diferencias entre la media global μ_1 y las medias condicionadas.

- Si $x_1 \perp \mathbf{x}_2$ entonces

$$\mathbb{E}(x_1|\mathbf{x}_2) = \int x_1 f(x_1|\mathbf{x}_2) dx_1 = \int x_1 f(x_1) dx_1 = \mathbb{E}(x_1) = \mu_1$$

y por lo tanto el segundo miembro $\text{var}(\mathbb{E}(x_1|\mathbf{x}_2)) = 0$

- En modelos lineales univariantes, si \bar{x} es la media global:

$$\frac{1}{n} \sum (x_i - \bar{x})^2 = \underbrace{\frac{1}{n} \sum (x_i - \hat{x}_i)^2}_{(C)} + \underbrace{\frac{1}{n} \sum (\hat{x}_i - \bar{x})^2}_{(B)}$$

Plan

1 Distribuciones multivariantes

2 **Distribución multinomial**

- Distribución binomial
- Distribución multinomial
- Ejemplo

3 Normal Multivariada

4 Distribuciones mezcladas

Distribución binomial

- 1 Queremos clasificar en dos clases A y B . Supongamos que $\mathbb{P}(A) = p (= \text{cte})$. La variable aleatoria considerada es

$$x = \begin{cases} 1, & \text{si la observación pertenece a } A \\ 0, & \text{si la observación no pertenece a } A \end{cases}$$

Entonces $x \sim \text{Ber}(p)$ con $\mathbb{P}(x = 1) = p$ y $\mathbb{P}(x = 0) = 1 - p$.

- 2 Supongamos que repetimos independientemente este experimento y tenemos n observaciones x_1, x_2, \dots, x_n . Defino $y = \sum_{i=1}^n x_i$ con $x_i \sim \text{Ber}(p)$. Se tiene que

$$\mathbb{P}(y = r) = \frac{n!}{r!(n-r)!} p^r (1-p)^{n-r} \quad \forall r = 0, \dots, n$$

Entonces $y \sim \text{Bin}(n, p)$

Distribución multinomial

- Supongamos que ahora tenemos G clases y $\mathbf{p} = (p_1, \dots, p_G)$ es un vector de probabilidad ($\sum_{g=1}^G p_g = 1$). Definimos

$$x_j = \begin{cases} 1, & \text{si la observación pertenece a } G_j \\ 0, & \text{si la observación no pertenece a } G_j \end{cases} \quad \forall j = 1, \dots, G$$

Entonces $\mathbf{x} = (x_1, \dots, x_G)$ es de la forma $(0, \dots, 0, 1, 0, \dots, 0)$. Las componentes de esta variable aleatoria no son independientes pues $\sum_{j=1}^G x_j = 1$, su distribución se llama *multinomial puntual* y tiene como función de probabilidad

$$\mathbb{P}(x_1, \dots, x_G) = p_1^{x_1} \dots p_G^{x_G}$$

y la probabilidad de que la j -ésima coordenada sea 1 es p_j .

Distribución multinomial

- Sea $\mathbf{x}_1, \dots, \mathbf{x}_n$ una muestra de n vectores de esta VA multinomial puntual. Por lo tanto esto es equivalente a clasificar n elementos de una muestra en G clases. Llamamos *distribución multinomial* a la distribución del vector

$$\mathbf{y} = \sum_{i=1}^n \mathbf{x}_i$$

Las componentes del vector \mathbf{y} corresponden a las frecuencias con que se observan cada clase en la muestra:

$$y_i \in \{0, 1, \dots, n\} \quad \sum_{i=1}^G y_i = n$$

$$\mathbb{P}(y_1 = n_1, \dots, y_G = n_G) = \frac{n!}{n_1! \dots n_G!} p_1^{n_1} \dots p_G^{n_G} \quad n = \sum_{i=1}^G n_i$$

Distribución multinomial

- Sea $\mathbf{x}_1, \dots, \mathbf{x}_n$ una muestra de n vectores de esta VA multinomial puntual. Por lo tanto esto es equivalente a clasificar n elementos de una muestra en G clases. Llamamos *distribución multinomial* a la distribución del vector

$$\mathbf{y} = \sum_{i=1}^n \mathbf{x}_i$$

Las componentes del vector \mathbf{y} corresponden a las frecuencias con que se observan cada clase en la muestra:

$$y_i \in \{0, 1, \dots, n\} \quad \sum_{i=1}^G y_i = n$$

$$\mathbb{P}(y_1 = n_1, \dots, y_G = n_G) = \frac{n!}{n_1! \dots n_G!} p_1^{n_1} \dots p_G^{n_G} \quad n = \sum_{i=1}^G n_i$$

Si \mathbf{y} tiene distribución multinomial notamos:

$$\mathbf{y} \sim \text{Mult}(n, \mathbf{p})$$

En este caso (ejercicio):

- 1 $\mathbb{E}(\mathbf{y}) = n\mathbf{p} = \boldsymbol{\mu}_y$
- 2 $\text{Var}(\mathbf{y}) = n(\text{diag}(\mathbf{p}) - \mathbf{p}\mathbf{p}') = \text{diag}(\boldsymbol{\mu}_y) - \frac{1}{n}\boldsymbol{\mu}_y\boldsymbol{\mu}_y'$

Distribución multinomial (ejemplo)

10 personas votan por 4 candidatos con probabilidades

$$P(1) = \frac{1}{2}, \quad P(2) = P(3) = \frac{1}{8}, \quad P(4) = \frac{1}{4}$$

Calcular la probabilidad que $(y_1, y_2, y_3, y_4) = (6, 1, 2, 1)$:

Distribución multinomial (ejemplo)

10 personas votan por 4 candidatos con probabilidades

$$\mathbb{P}(1) = \frac{1}{2}, \quad \mathbb{P}(2) = \mathbb{P}(3) = \frac{1}{8}, \quad \mathbb{P}(4) = \frac{1}{4}$$

Calcular la probabilidad que $(y_1, y_2, y_3, y_4) = (6, 1, 2, 1)$:

$$\mathbb{P}(y_1 = 6, y_2 = 1, y_3 = 2, y_4 = 1) = \frac{10!}{6!1!2!1!} \left(\frac{1}{2}\right)^6 \left(\frac{1}{8}\right)^1 \left(\frac{1}{8}\right)^2 \left(\frac{1}{4}\right)^1$$

Plan

- 1 Distribuciones multivariantes
- 2 Distribución multinomial
- 3 Normal Multivariada**
 - Normal univariada
 - Normal multivariada
 - Ejemplo
 - Densidad de una normal multivariada
 - Propiedades
- 4 Distribuciones mezcladas

Normal univariada

Recordamos:

- 1 la densidad de una normal univariada típica

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2}$$

y escribimos $x \sim N(0, 1)$

Normal univariada

Recordamos:

- 1 la densidad de una normal univariada típica

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2}$$

y escribimos $x \sim N(0, 1)$

- 2 la densidad de una normal univariada

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

y escribimos $x \sim N(\mu, \sigma^2)$

Normal univariada

Recordamos:

- 1 la densidad de una normal univariada típica

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2}$$

y escribimos $x \sim N(0, 1)$

- 2 la densidad de una normal univariada

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

y escribimos $x \sim N(\mu, \sigma^2)$

Observaciones:

- Si σ es grande el pico de la gaussiana es chico y si σ es chico el pico de la gaussiana es grande.
- Si $x \sim N(\mu, \sigma^2)$ entonces $z = \frac{x-\mu}{\sigma} \sim N(0, 1)$.

Normal univariada





Figura: En negro $N(0, 1)$ y en rojo $N(0, 0.4)$

Normal univariada



$$\mathbb{P}(\mu - \sigma < X < \mu + \sigma) = \mathbb{P}\left(-1 < \frac{X - \mu}{\sigma} < 1\right) = \Phi(1) - \Phi(-1) = 2\Phi(1) - 1 \approx 2 \times 0,84 - 1 \approx 0,682$$

Normal multivariada

Decimos que $\mathbf{x} = (x_1, \dots, x_d)$ es **gaussiana típica** en \mathbb{R}^d si tiene densidad conjunta

$$f_{\mathbf{x}}(\mathbf{x}) = \frac{1}{(2\pi)^{\frac{d}{2}}} e^{-\frac{1}{2}\|\mathbf{x}\|^2}$$

Notación:

$$\mathbf{x} \sim N(0_{\mathbb{R}^d}, I_d)$$

Normal multivariada

Decimos que $\mathbf{x} = (x_1, \dots, x_d)$ es **gaussiana típica** en \mathbb{R}^d si tiene densidad conjunta

$$f_{\mathbf{x}}(\mathbf{x}) = \frac{1}{(2\pi)^{\frac{d}{2}}} e^{-\frac{1}{2}\|\mathbf{x}\|^2}$$

Notación:

$$\mathbf{x} \sim N(0_{\mathbb{R}^d}, I_d)$$

Decimos que \mathbf{y} es **gaussiana** en \mathbb{R}^d o **normal multivariada** con media $\mu \in \mathbb{R}^d$ y matriz de covarianza $\Sigma = AA'$ siendo $A \in \mathcal{M}_{d \times d}$ si \mathbf{y} tiene la misma distribución que $\mu + A\mathbf{x}$ con $\mathbf{x} \sim N(0_{\mathbb{R}^d}, I_d)$.

Notación:

$$\mathbf{y} \sim N(\mu, \Sigma)$$

Normal multivariada: ejemplo

Sea $\mathbf{x} = (x_1, x_2) \sim N(0_{\mathbb{R}^2}, I_2)$

Si defino

$$\mathbf{y} = \begin{pmatrix} 1 \\ 1 \end{pmatrix} + \begin{pmatrix} 1 & 0 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

Entonces

$$\mathbf{y} \sim N\left(\begin{pmatrix} 1 \\ 1 \end{pmatrix}, \begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix}\right)$$

Normal bivariada

library(mvtnorm) library(MASS)




Figura: $N(\mu, \Sigma)$ con $\mu = (0, 0)$ y $\Sigma = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$

Densidad de una normal $N(\mu, \Sigma)$

Si \mathbf{y} es **gaussiana** en \mathbb{R}^d , $\mathbf{y} \sim N(\mu, \Sigma)$ con $\Sigma = AA'$ e $\mathbf{y} = \mu + A\mathbf{x}$ entonces

$$\mathbf{y} = Q(\mathbf{x})$$

con $Q : \mathbb{R}^d \rightarrow \mathbb{R}^d$ definida por $Q(\mathbf{x}) = \mu + A\mathbf{x}$.

¹Si $\mathbf{y} = A\mathbf{x} + \mu$ entonces $f_{\mathbf{y}}(\mathbf{y}) = f_{\mathbf{x}}(A^{-1}(\mathbf{y} - \mu))|\det(A)^{-1}|$

Densidad de una normal $N(\mu, \Sigma)$

Si \mathbf{y} es **gaussiana** en \mathbb{R}^d , $\mathbf{y} \sim N(\mu, \Sigma)$ con $\Sigma = AA'$ e $\mathbf{y} = \mu + A\mathbf{x}$ entonces

$$\mathbf{y} = Q(\mathbf{x})$$

con $Q : \mathbb{R}^d \rightarrow \mathbb{R}^d$ definida por $Q(\mathbf{x}) = \mu + A\mathbf{x}$.

Supongamos que A es invertible, entonces Q es biyectiva, $J_Q = \det(A)$ y por lo tanto, por el teorema del Jacobiano ¹, Y es absolutamente continua con densidad:

$$\begin{aligned} f_Y(\mathbf{y}) &= f_{Q(\mathbf{x})}(\mathbf{y}) = f_X(A^{-1}(\mathbf{y} - \mu)) \frac{1}{\sqrt{\det(\Sigma)}} = \frac{1}{(2\pi)^{d/2} \sqrt{\det(\Sigma)}} e^{-\frac{1}{2} \|A^{-1}(\mathbf{y} - \mu)\|^2} \\ &= \frac{1}{(2\pi)^{d/2} \sqrt{\det(\Sigma)}} e^{-\frac{1}{2} (A^{-1}(\mathbf{y} - \mu))' A^{-1}(\mathbf{y} - \mu)} = \frac{1}{(2\pi)^{d/2} \sqrt{\det(\Sigma)}} e^{-\frac{1}{2} (\mathbf{y} - \mu)' \Sigma^{-1} (\mathbf{y} - \mu)} \end{aligned}$$

y por lo tanto

$$f_Y(\mathbf{x}) = \frac{1}{(2\pi)^{d/2} \sqrt{\det(\Sigma)}} e^{-\frac{1}{2} (\mathbf{x} - \mu)' \Sigma^{-1} (\mathbf{x} - \mu)}$$

¹Si $\mathbf{y} = A\mathbf{x} + \mu$ entonces $f_Y(\mathbf{y}) = f_X(A^{-1}(\mathbf{y} - \mu)) |\det(A)^{-1}|$

Normal multivariada (teoremas)

Se puede probar:

- 1 Si $\mathbf{x} = (x_1, \dots, x_d) \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ entonces x_1, \dots, x_d independientes si y sólo si son incorrelacionadas (es decir $\boldsymbol{\Sigma}$ es una matriz diagonal).

Normal multivariada (teoremas)

Se puede probar:

- 1 Si $\mathbf{x} = (x_1, \dots, x_d) \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ entonces x_1, \dots, x_d independientes si y sólo si son incorrelacionadas (es decir $\boldsymbol{\Sigma}$ es una matriz diagonal).
- ▶ Es bien conocido que si x_1, \dots, x_d son independientes entonces x_1, \dots, x_d están incorrelacionadas y esto implica que la matriz de varianzas del vector $\mathbf{x} = (x_1, \dots, x_d)$ es diagonal.

Normal multivariada (teoremas)

Se puede probar:

- 1 Si $\mathbf{x} = (x_1, \dots, x_d) \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ entonces x_1, \dots, x_d independientes si y sólo si son incorrelacionadas (es decir $\boldsymbol{\Sigma}$ es una matriz diagonal).
- ▶ Es bien conocido que si x_1, \dots, x_d son independientes entonces x_1, \dots, x_d están incorrelacionadas y esto implica que la matriz de varianzas del vector $\mathbf{x} = (x_1, \dots, x_d)$ es diagonal.
- ▶ El recíproco no es siempre cierto en general, pero si x es gaussiano se cumple, pues

$$f_{\mathbf{x}}(x) = \prod_{i=1}^d f_{x_i}(x_i)$$

Normal multivariada (teoremas)

Se puede probar:

- 1 Si $\mathbf{x} = (x_1, \dots, x_d) \sim N(\mu, \Sigma)$ entonces x_1, \dots, x_d independientes si y sólo si son incorrelacionadas (es decir Σ es una matriz diagonal).
 - ▶ Es bien conocido que si x_1, \dots, x_d son independientes entonces x_1, \dots, x_d están incorrelacionadas y esto implica que la matriz de varianzas del vector $\mathbf{x} = (x_1, \dots, x_d)$ es diagonal.
 - ▶ El recíproco no es siempre cierto en general, pero si x es gaussiano se cumple, pues

$$f_{\mathbf{x}}(x) = \prod_{i=1}^d f_{x_i}(x_i)$$

- 2 Si $\mathbf{x}_1, \dots, \mathbf{x}_n$ es una sucesión de vectores aleatorios i.i.d, con $E(\mathbf{x}_1) = \mu$ y matriz de covarianzas Σ entonces

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n (\mathbf{x}_i - \mu) \xrightarrow{D} N_d(0_{\mathbb{R}^d}, \Sigma)$$

Distribución normal bivariada

La distribución normal de un vector (x_1, x_2) de media $\mu = (\mu_1, \mu_2)$ y matriz de covarianza

$$\Sigma = \begin{pmatrix} \sigma_1^2 & \text{cov}(x_1, x_2) \\ \text{cov}(x_2, x_1) & \sigma_2^2 \end{pmatrix}$$

tiene como densidad

$$f_{(x_1, x_2)}(x_1, x_2) = \frac{1}{(\sqrt{2\pi})^2 \sqrt{\det(\Sigma)}} \exp\left(-\frac{1}{2}(x_1 - \mu_1 \ x_2 - \mu_2)\Sigma^{-1} \begin{pmatrix} x_1 - \mu_1 \\ x_2 - \mu_2 \end{pmatrix}\right)$$

Normal multivariada




Figura: $\Sigma = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$

$$\mathbb{P}(X_2 > 0 | X_1 > 2) = \mathbb{P}(X_2 > 0)$$




Figura: $\Sigma = \begin{pmatrix} 1 & 0,8 \\ 0,8 & 1 \end{pmatrix}$

$$\mathbb{P}(X_2 > 0 | X_1 > 2) > \mathbb{P}(X_2 > 0)$$

Normal Multivariada (propiedades)

Sea $\mathbf{x} \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ entonces tenemos las siguientes propiedades:

- 1 La distribución es simétrica alrededor de $\boldsymbol{\mu}$.
Esto es porque $f(\boldsymbol{\mu} + \mathbf{a}) = f(\boldsymbol{\mu} - \mathbf{a})$.
- 2 La distribución tiene un único máximo en $\boldsymbol{\mu}$.
Al ser $\boldsymbol{\Sigma}$ definida positiva, el término del exponente $(\mathbf{x} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})$ es siempre positivo, y $f(\mathbf{x})$ es máxima cuando este término es nulo, o sea si $\mathbf{x} = \boldsymbol{\mu}$.
- 3 La media es $\boldsymbol{\mu}$ y la matriz de varianzas-covarianzas es $\boldsymbol{\Sigma}$.
- 4 Las distribuciones marginales son normales.
- 5 Si $\mathbf{x} \in \mathbb{R}^d$ es normal y $\mathbf{A} \in \mathcal{M}_{k \times d}$ es una matriz entonces $\mathbf{y} = \mathbf{A}\mathbf{x} \in \mathbb{R}^k$ es normal.

Test normalidad en R

Nos preguntamos si los datos tienen distribución normal. Para eso podemos recurrir a la adaptación del test de normalidad de Shapiro-Wilk para datos multivariados.

```
library(mvnormtest)
x=iris[,1:4]
x=as.matrix(x)
mshapiro.test(t(x))
```

Normal Multivariada

Si cortamos con hiperplanos paralelos a las p variables, se obtienen curvas de nivel ² cuya ecuación es

$$(\mathbf{x} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) = cte \quad (\text{elipsoides})$$

y define entonces una medida de la distancia de \mathbf{x} al centro $\boldsymbol{\mu}$.

Esta medida se llama distancia de Mahalanobis y

$$D^2 = (\mathbf{x} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})$$

Supongamos que tenemos dos normales $N(0, 1)$ y $N(10, 10^2)$. Sea $x = 3$, entonces:

- 1 La distancia euclídea de $x = 3$ a 0 es más corta que la distancia de 3 a 10.
- 2 La distancia de Mahalanobis de $x = 3$ a la distribución que tiene desviación típica 1 es $(3 - 0)1(3 - 0) = 9$
- 3 La distancia de Mahalanobis de $x = 3$ a la distribución que tiene desviación típica 10 es $(3 - 10) \frac{1}{100} (3 - 10) = 0,49$

Con la distancia de Mahalanobis, el punto $x = 3$ está más cerca de la segunda distribución. Es más probable que provenga de ella (lo veremos en breve).

²La curva de nivel α de una función $f : \mathbb{R}^d \rightarrow \mathbb{R}$ se define como $C_\alpha = \{\mathbf{x} \in \mathbb{R}^d : f(\mathbf{x}) = \alpha\}$

Plan

- 1 Distribuciones multivariantes
- 2 Distribución multinomial
- 3 Normal Multivariada
- 4 Distribuciones mezcladas**

Distribuciones mezcladas

Muchas veces los datos multivariantes provienen de poblaciones distintas. Si suponemos que tenemos G poblaciones, entonces

$$\mathbb{P}(\mathbf{x} \in A) = \sum_{i=1}^G \mathbb{P}(\mathbf{x} \in A, \mathbf{x} \in i) = \sum_{i=1}^G \mathbb{P}(\mathbf{x} \in A | \mathbf{x} \in i) \mathbb{P}(\mathbf{x} \in i) = \sum_{i=1}^G \pi_i \mathbb{P}(\mathbf{x} \in A | \mathbf{x} \in i)$$

y por lo tanto la función de densidad de la población es

$$f(\mathbf{x}) = \sum_{i=1}^G \pi_i f_i(\mathbf{x})$$

Distribuciones mezcladas

Muchas veces los datos multivariantes provienen de poblaciones distintas. Si suponemos que tenemos G poblaciones, entonces

$$\mathbb{P}(\mathbf{x} \in A) = \sum_{i=1}^G \mathbb{P}(\mathbf{x} \in A, \mathbf{x} \in i) = \sum_{i=1}^G \mathbb{P}(\mathbf{x} \in A | \mathbf{x} \in i) \mathbb{P}(\mathbf{x} \in i) = \sum_{i=1}^G \pi_i \mathbb{P}(\mathbf{x} \in A | \mathbf{x} \in i)$$

y por lo tanto la función de densidad de la población es

$$f(\mathbf{x}) = \sum_{i=1}^G \pi_i f_i(\mathbf{x})$$

Se prueba que

- 1 La media de una mezcla es




$$\mu = \sum_{i=1}^G \pi_i \mu_i$$

- 2 La matriz de varianzas y covarianzas de una mezcla es


$$V = \sum_{i=1}^G \pi_i V_i + \sum_{i=1}^G \pi_i (\mu_i - \mu)(\mu_i - \mu)'$$

donde V_i es la matriz de varianzas y covarianzas de la distribución i .

Mezcla de normales multivariadas



Mezcla de tres normales



Referencias

- D. Peña, *Análisis de Datos Multivariantes*, Mac Graw Hill, 2002.
- A. I. Izenman, *Modern Multivariate Statistical Techniques*, Springer, 2008.