

Distribuciones multivariadas

Si X_1, X_2, \dots, X_p son variables aleatorias *discretas*, definiremos la *función de probabilidad conjunta* de \mathbf{X} como

$$p(\mathbf{x}) = p(x_1, x_2, \dots, x_k) = P(X_1 = x_1, X_2 = x_2, \dots, X_p = x_p)$$

Propiedades:

- $p(\mathbf{x}) \geq 0$ para todo \mathbf{x} .
- $\sum p(\mathbf{x}) = 1$, donde la suma se toma sobre todos los posibles valores de \mathbf{x} .

La *función de probabilidad marginal* para la variable X_i se define como

$$p_i(x_i) = P(X_i = x_i) = \sum p(x_1, \dots, x_i, \dots, x_p)$$

donde la suma se realiza sobre todos \mathbf{x} tales que su i -ésima componente es x_i .

Diremos que X_1, X_2, \dots, X_p son *independientes* si

$$p(\mathbf{x}) = \prod_{i=1}^p p_i(x_i)$$

Recordemos que la probabilidad condicional del evento A dado que ocurre el evento B se define como:

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

Análogamente, si X_1 y X_2 son variables aleatorias discretas, definiremos la *función de probabilidad condicional* de X_1 dado $X_2 = x_2$ como

$$p(x_1|x_2) = P(X_1 = x_1|X_2 = x_2) = \frac{p(x_1, x_2)}{p(x_2)}$$

Con mayor generalidad, puede definirse

$$p(x_1, \dots, x_k|x_{k+1}, \dots, x_p) = \frac{p(\mathbf{x})}{p(x_{k+1}, \dots, x_p)}$$

En el caso de variables aleatorias continuas, definiremos análogos para la función de densidad y la función de distribución. La *función de distribución conjunta* de X_1, X_2, \dots, X_p se definirá como

$$F(\mathbf{x}) = F(x_1, \dots, x_p) = P(X_1 \leq x_1, \dots, X_p \leq x_p)$$

(Nótese que esta definición es válida también para variables discretas)

La *función de densidad conjunta* es la función $f(\mathbf{x}) = f(x_1, \dots, x_p)$ tal que

$$F(\mathbf{x}) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_p} f(u_1, \dots, u_p) du_1 \dots du_p$$

En este caso,

$$f(\mathbf{x}) = \frac{\partial^p F(x_1, \dots, x_p)}{\partial x_1 \partial x_2 \dots \partial x_p}$$

La función de densidad conjunta satisface las siguientes propiedades:

- $f(\mathbf{x}) \geq 0$ para todo \mathbf{x} .
- $\int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(\mathbf{x}) dx_1 \dots dx_p = 1$.

Distribuciones marginales y condicionales pueden ser definidas en el caso continuo de manera análoga al caso discreto.

$$f_i(x_i) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(\mathbf{x}) dx_1 \dots dx_{i-1} dx_{i+1} \dots dx_p = 1$$

$$f(x_1|x_2) = \frac{f(x_1, x_2)}{f(x_2)}$$

o, más generalmente,

$$f(x_1, \dots, x_k | x_{k+1}, \dots, x_p) = \frac{f(\mathbf{x})}{f(x_{k+1}, \dots, x_p)}$$

Medias, varianzas y correlaciones

El valor esperado de \mathbf{X} es el vector $\boldsymbol{\mu}^T = [\mu_1, \dots, \mu_p]$ tal que

$$\mu_i = E(X_i) = \int_{-\infty}^{\infty} x f_i(x) dx$$

es la media de la i -ésima componente de \mathbf{X} . (Si X_i es discreta,

$$\mu_i = E(X_i) = \sum x p_i(x))$$

La varianza de la i -ésima componente de \mathbf{X} viene dada por

$$\sigma_i^2 = Var(X_i) = E(X_i - \mu_i)^2 = EX_i^2 - \mu_i^2$$

La covarianza de dos variables X_i y X_j se define como

$$\sigma_{ij} = Cov(X_i, X_j) = E[(X_i - \mu_i)(X_j - \mu_j)] = E(X_i X_j) - \mu_i \mu_j$$

Nótese que $\sigma_{ii} = \sigma_i^2$

Cuando se trabaja con p variables, se tienen p varianzas y $\frac{1}{2}p(p-1)$ covarianzas. En este caso, es útil presentar todas estas cantidades en una matriz $p \times p$ de la siguiente manera:

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{12} & \sigma_2^2 & \dots & \sigma_{2p} \\ \vdots & & & \\ \sigma_{p1} & \sigma_{p2} & \dots & \sigma_p^2 \end{bmatrix}$$

Esta matriz se denomina *matriz de dispersión*, *matriz de variancia y covarianza* o simplemente *matriz de covarianza*. Nótese que esta matriz es simétrica.

Σ puede también escribirse en alguna de las siguientes formas:

$$\begin{aligned} \Sigma &= E[(\mathbf{X} - \boldsymbol{\mu})(\mathbf{X} - \boldsymbol{\mu})^T] \\ &= E[\mathbf{X}\mathbf{X}^T] - \boldsymbol{\mu}\boldsymbol{\mu}^T \end{aligned}$$

Consideremos ahora la variable aleatoria univariada Y definida como una combinación lineal de X_1, \dots, X_p . En ese caso

$$Y = \mathbf{a}^T \mathbf{X}$$

donde $\mathbf{a}^T = [a_1, a_2, \dots, a_p]$ es un vector de constantes. Entonces

$$E(Y) = \mathbf{a}^T \boldsymbol{\mu}$$

y

$$Var(Y) = \mathbf{a}^T \Sigma \mathbf{a}$$

Estos resultados pueden generalizarse al caso en el cual A es una matriz de constantes $p \times m$. En ese caso $A^T \mathbf{X}$ es un vector $m \times 1$, y tiene vector de medias y matriz de covarianza dados por las siguientes expresiones:

$$E(A^T \mathbf{X}) = A^T \boldsymbol{\mu}$$

$$Var(A^T \mathbf{X}) = A^T \Sigma A$$

La *correlación* entre dos variables aleatorias X_i y X_j se define como

$$\rho_{ij} = \frac{\sigma_{ij}}{\sigma_i \sigma_j}$$

- Es una medida de dependencia *lineal* entre variables.
- $|\rho_{ij}| < 1$
- Si X_i y X_j son independientes, $\rho_{ij} = 0$. El recíproco no es cierto.

Cuando se tienen p variables X_1, X_2, \dots, X_p , es en general conveniente presentar las $p(p-1)/2$ correlaciones en una matriz simétrica cuyo elemento ij es ρ_{ij} (nótese que todos los elementos de la diagonal son 1). Esta matriz se denomina *matriz de correlación* y se denotará por P .

Si definimos $D = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_p)$, puede verse que:

$$\begin{aligned}\Sigma &= DPD \\ P &= D^{-1}\Sigma D^{-1}\end{aligned}$$

Tanto Σ como P son matrices semipositivo definidas, y tienen el mismo rango. Si $\text{rango}(\Sigma) = \text{rango}(P) = p$, las matrices son positivo definidas.

Distribución Normal multivariada

En el caso univariado, decimos que una variable aleatoria X tiene distribución normal con media μ y varianza σ^2 ($X \sim N(\mu, \sigma^2)$) si su función de densidad tiene la forma

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp[-(x - \mu)^2/2\sigma^2]$$

En el caso multivariado, decimos que el vector \mathbf{X} sigue una distribución normal multivariada si su función de densidad conjunta es de la forma

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

donde Σ es una matriz $p \times p$ no singular, simétrica y positiva definida.

Si $|\Sigma| = 0$, \mathbf{x} tienen una distribución degenerada.

Caso Bi-variado

En este caso $X = (X_1, X_2)$; la media es $\theta = (\mu_1, \mu_2)$ y la matriz de Varianza-Covarianza tienen la forma:

$$\Sigma = \begin{pmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{12} & \sigma_2^2 \end{pmatrix}$$

donde $|\Sigma| = \sigma_1^2 \sigma_2^2 (1 - \rho^2)$; ρ es la correlación entre X_1 y X_2 y $\sigma_{12} = \rho \sigma_1 \sigma_2$ es la covarianza entre X_1 y X_2 .

- Si $\rho = 0$ X_1 y X_2 no están correlacionadas y además son independientes.
- Si X_1 y X_2 son independientes esto implica que X_1 y X_2 no están correlacionadas. Esto se cumple para todas las distribuciones bivariadas.
- Si $\rho = 0$ esto no implica independencia. Sin embargo esta afirmación si es cierta para la distribución normal.

Distribuciones marginales normales

$$\text{Sea } X = \begin{pmatrix} Y \\ Z \end{pmatrix}; \theta = \begin{pmatrix} \theta_Y \\ \theta_Z \end{pmatrix}; \Sigma = \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix}$$

donde:

$$Y : q \times 1, \Sigma_{11} : q \times q$$

$$Z : r \times 1, \Sigma_{22} : r \times r$$

$$\theta_Y : q \times 1, \Sigma_{12} : q \times r$$

$$\theta_Z : r \times 1, q + r = p$$

Si $\Sigma_{11} > 0$ y $\Sigma_{22} > 0$, Y y Z tienen densidades:

$$Y \sim N(\theta_Y, \Sigma_{11})$$

$$Z \sim N(\theta_Z, \Sigma_{22})$$

Esto se puede demostrar calculando por ejemplo la distribución marginal de:

$$g(y) = \int f(y, z) dz$$

Distribuciones normales condicionales

Sea $X : p \times 1$ un vector de variables aleatorias tal que:

$$\mathbf{X} \sim N(\theta, \Sigma)$$

Entonces la distribución condicional:

$$Y|Z = z \sim N(\theta_Y + \Sigma_{12}\Sigma_{22}^{-1}(z - \theta_Z), \Sigma_{11,2})$$

donde $\Sigma_{11,2} = \Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}$.

En el caso bi-dimensional: $X = (X_1, X_2)'$; $\theta = (\theta_1, \theta_2)$

$\Sigma_{11} = \sigma_1^2$, $\Sigma_{12} = \rho\sigma_1\sigma_2$, $\Sigma_{22} = \sigma_2^2$ y $\Sigma_{11,2} = \sigma_1^2(1 - \rho^2)$

Media muestral y matriz de covarianza muestral

Sean $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$ observaciones de una variable aleatoria $\mathbf{X}_{p \times 1}$. Entonces el vector de medias muestrales se calcula como

$$\bar{\mathbf{X}} = \begin{bmatrix} \bar{X}_{.1} \\ \bar{X}_{.2} \\ \vdots \\ \bar{X}_{.p} \end{bmatrix}$$

donde $\bar{X}_{.j} = \frac{1}{n} \sum_{i=1}^n X_{ij}$.

La matriz de covarianza muestral S contiene los siguientes elementos:

$$s_{jj} = \frac{\sum_{i=1}^n (X_{ij} - \bar{X}_{.j})^2}{n-1}$$
$$s_{jk} = \frac{\sum_{i=1}^n (X_{ij} - \bar{X}_{.j})(X_{ik} - \bar{X}_{.k})}{n-1}, \quad i \neq j$$

S puede escribirse con $\frac{1}{n-1} X^{*T} X^*$, donde

$$X^* = \begin{bmatrix} X_{11} - \bar{X}_{.1} & X_{12} - \bar{X}_{.2} & \dots & X_{1p} - \bar{X}_{.p} \\ X_{21} - \bar{X}_{.1} & X_{22} - \bar{X}_{.2} & \dots & X_{2p} - \bar{X}_{.p} \\ \vdots & & & \\ X_{n1} - \bar{X}_{.1} & X_{n2} - \bar{X}_{.2} & \dots & X_{np} - \bar{X}_{.p} \end{bmatrix}$$

La matriz de correlación muestral R tiene elementos

$$r_{jk} = \frac{s_{jk}}{s_j s_k}$$

(Nótese que si $j = k$, $r_{jk} = 1$)

R puede escribirse como $R = \frac{1}{n-1} \tilde{X}^T \tilde{X}$, donde

$$\tilde{X} = \begin{bmatrix} (X_{11} - \bar{X}_{,1})/s_1 & (X_{12} - \bar{X}_{,2})/s_2 & \dots & (X_{1p} - \bar{X}_{,p})/s_p \\ (X_{21} - \bar{X}_{,1})/s_1 & (X_{22} - \bar{X}_{,2})/s_2 & \dots & (X_{2p} - \bar{X}_{,p})/s_p \\ \vdots & & & \\ (X_{n1} - \bar{X}_{,1})/s_1 & (X_{n2} - \bar{X}_{,2})/s_2 & \dots & (X_{np} - \bar{X}_{,p})/s_p \end{bmatrix}$$

La matriz de covarianza muestral y la matriz de correlación muestral se relacionan a través de la expresión

$$R = D^{-1/2} S D^{-1/2}$$

donde $D = \text{diag}(s_1^2, s_2^2, \dots, s_p^2)$.

Teorema del Límite Central Multivariado

Si las filas de la matriz de datos X representan una muestra de una variable aleatoria multivariada \mathbf{X} con $E(\mathbf{X}) = \boldsymbol{\mu}$ y $Cov(\mathbf{X}) = \Sigma$, entonces la distribución asintótica de $\bar{\mathbf{X}}$ es una normal multivariada con vector de medias $\boldsymbol{\mu}$ y matriz de covarianza $\frac{1}{n}\Sigma$.