



FACULTAD de
CIENCIAS ECONÓMICAS

DISTRIBUCIONES MULTIVARIADAS

ALAN REYES-FIGUEROA
ELEMENTS OF MACHINE LEARNING

(AULA 05) 27.ENERO.2025

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 Σ 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. Σ es simétrica (como consecuencia, tiene autovalores reales).
2. Σ 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 Σ 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 $\text{Cov}(X, Y) = \mathbf{0}$,
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

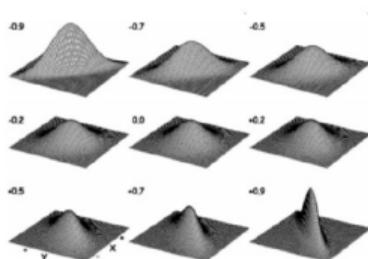
Típicamente la matriz Σ proporciona información sobre la relación entre las variables componentes.

$Cov(X) = [Cov(X_i, X_j)]$ 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 μ y Σ 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 Σ 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 el caso discreto, $H(X) = - \sum_x \mathbb{P}(X = x) \log \mathbb{P}(X = x)$.

Definición

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

$$H(X) = 1 - \int_{\mathbb{R}} f_X^2(t) dt.$$

En el caso discreto, $H(X) = \sum_x \mathbb{P}(X = x) (1 - \mathbb{P}(X = x)) = 1 - \sum_x \mathbb{P}(X = x)^2$.

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

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

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

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