

ALGUNOS EJEMPLOS DE DISTRIBUCIONES

ALAN REYES-FIGUEROA

INTRODUCCIÓN A LA CIENCIA DE DATOS

(AULA 09) 02.FEBRERO.2022

Variables aleatorias continuas

- distribución Uniforme $U[a..b]$,
- distribución Normal $\mathcal{N}(\mu, \sigma^2)$,
- distribución Lognormal $\mathcal{LN}(\mu, \sigma^2)$,

- distribución Exponencial $Exp(\lambda)$,
- distribución Erlang $Erlang(n, \lambda)$,
- distribución Gamma $\Gamma(\alpha, \beta)$,
- distribución Beta $Beta(\alpha, \beta)$,

- distribución Weibull,
- distribución Pareto,
- distribuciones de valores extremos.

Variables aleatorias continuas

1. Distribución Uniforme

$$X \sim U[a..b] \Leftrightarrow f_X(t) = \frac{1}{b-a} \mathbf{1}_{[a,b]}(t).$$

Obs. Aquí la función $\mathbf{1}_{[a,b]}$ es una *función indicadora* o *función característica*, que indica cuál es el soporte de la distribución.

Recordemos que para cualquier subconjunto $A \subseteq \mathbb{R}$

$$\mathbf{1}_A(t) = \begin{cases} 1, & t \in A; \\ 0, & t \notin A. \end{cases}$$

Preguntas: ¿Cuál es la función de distribución F_X ? ¿ $\mathbb{E}(X)$, $\text{Var}(X)$?

2. Distribución Exponencial Dado un parámetro $\lambda > 0$, la distribución exponencial tiene densidad

$$f_X(t) = \lambda e^{-\lambda t} \mathbf{1}_{[0, \infty)}(t), \quad F_X(t) = (1 - e^{-\lambda t}) \mathbf{1}_{[0, \infty)}(t).$$

Obs.

- $\mathbb{E}(X) = \frac{1}{\lambda}$ y $\text{Var}(X) = \frac{1}{\lambda^2}$.
- En ocasiones, se parametriza en términos de su valor esperado $\theta = \frac{1}{\lambda}$:

$$f_X(t) = \frac{1}{\theta} e^{-t/\theta} \mathbf{1}_{[0, \infty)}(t).$$

Variables aleatorias continuas


3. Distribución Normal Dados dos parámetros $\mu \in \mathbb{R}$, $\sigma > 0$, la distribución normal tiene densidad

$$f_X(t) = \frac{1}{(2\pi\sigma^2)^{1/2}} \exp\left(-\frac{(X - \mu)^2}{2\sigma^2}\right) \mathbf{1}_{\mathbb{R}}(t).$$

Obs.

- $\mathbb{E}(X) = \mu$ y $\text{Var}(X) = \sigma^2$.
- La distribución es simétrica alrededor de μ .
- X no tiene una función de distribución elemental

$$F_X(x) = \int_{-\infty}^x f_X(t) dt.$$



Propiedades

1. Si $X \sim \mathcal{N}(\mu, \sigma^2)$, se tiene que $Z = \frac{X-\mu}{\sigma} \sim \mathcal{N}(0, 1)$.
2. Si $X_1 \sim \mathcal{N}(\mu_1, \sigma_1^2)$ y $X_2 \sim \mathcal{N}(\mu_2, \sigma_2^2)$, y X_1, X_2 son independientes, entonces

$$X_1 + X_2 \sim \mathcal{N}(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$$

3. Si $X \sim \mathcal{N}(\mu, \sigma^2)$, se tiene que $-X \sim \mathcal{N}(-\mu, \sigma^2)$.
4. En general, si $X \sim \mathcal{N}(\mu, \sigma^2)$, y $a, b \in \mathbb{R}$, entonces $Y = aX + b$ es normal, con

$$Y \sim \mathcal{N}(a\mu + b, a^2\sigma^2).$$

Teoremas importantes

Teorema (Desigualdad de Markov)

Si X es una v.a. no-negativa, $a > 0$, entonces

$$\mathbb{P}(X \geq a) \leq \frac{\mathbb{E}(X)}{a}.$$

Teorema (Desigualdad de Tchebyshev)

Si X es una v.a. con $\mathbb{E}(X)$ y $\text{Var}(X)$ finitas, $a > 0$, entonces

$$\mathbb{P}(|X - \mathbb{E}(X)| \geq a) \leq \frac{\text{Var}(X)}{a^2}.$$

Teoremas importantes

Teorema (Ley débil de los números grandes)

Sean X_1, X_2, \dots, X_n variables aleatorias i.i.d., con $\mathbb{E}(X_i) < \infty$. Entonces, para todo $\epsilon > 0$


$$\lim_{n \rightarrow \infty} \mathbb{P}\left(\left|\frac{X_1, X_2, \dots, X_n}{n} - \mathbb{E}(X)\right| > \epsilon\right) = 0.$$

Interpretación:

Se repite el experimento n veces, con resultados X_i .

$\mathbb{E}(X) = \mathbb{P}(A)$, entonces $\frac{X_1, X_2, \dots, X_n}{n}$ es el porcentaje de veces que ocurrió A .

La ley débil dice que el porcentaje de veces A ocurrió en n repeticiones se aproxima a $\mathbb{E}(X)$.



Teoremas importantes

Teorema (Teorema Central de Límite)

Sean X_1, X_2, \dots, X_n variables aleatorias i.i.d., con $\mathbb{E}(X_i) = \mu$, $\text{Var}(X_i) = \sigma^2$ finitas. Entonces


$$\lim_{n \rightarrow \infty} \mathbb{P}\left(\frac{S_n/n - \mu}{\sigma^2/\sqrt{n}} \leq x\right) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-t^2/2} dt.$$

Consecuencias:

$$\frac{S_n}{n} \sim \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right),$$

o equivalentemente

$$X_1 + \dots + X_n = S_n \sim \mathcal{N}(n\mu, n\sigma^2).$$



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 $\text{Cov}(X, Y) = 0$,
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 $\text{Var}(X) = L^T I_d L = L^T L = \Sigma$.