

# Variables Aleatorias Continuas (continuación)

Pablo L. De Nápoli

Departamento de Matemática  
Facultad de Ciencias Exactas y Naturales  
Universidad de Buenos Aires

Probabilidades y Estadística para Matemática  
Segundo cuatrimestre de 2021

# Recordamos las definiciones básicas

Supongamos que tenemos una distribución de probabilidades continua con densidad  $f(x)$  y función de distribución acumulada

$$F(x) = \int_{-\infty}^x f(t) dt$$

Si  $X$  es una variable aleatoria con esta distribución

$$F(x) = P\{X \leq x\}$$

y si  $I = (a, b]$  es un intervalo semiabierto

$$P\{X \in I\} = F(b) - F(a) = \int_a^b f(x) dx$$

Supondremos hoy (para evitar complicaciones técnicas) que  $f(x)$  es continua y positiva. Con lo que  $F$  será estrictamente creciente y  $F' = f$ .

# Parámetros de Posición

Podemos considerar tres **parámetros de posición** diferentes:

- La esperanza, media o valor medio:

$$E[X] = \int_{-\infty}^{\infty} x dF(x) = \int_{-\infty}^{\infty} x f(x) dx$$

- La **mediana** es aquel valor de  $x_0$  para el cual

$$P\{X \leq x_0\} = P\{X > x_0\} = \frac{1}{2}$$

es decir  $\text{mediana}(X) = F^{-1}(1/2)$ .

- La **moda** es aquél valor de  $x$  para el cuál  $f(x)$  es máximo. (podría haber más de uno, se distingue entonces entre distribuciones **unimodales** o **multimodales**).


# Un ejemplo: la distribución normal

Consideremos como un primer ejemplo, la distribución normal  $N(\mu, \sigma^2)$ :

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-(x-\mu)^2/(2\sigma^2)}$$


donde  $\mu, \sigma \in \mathbb{R}$  y  $\sigma > 0$ . En este caso

$$E[X] = \text{mediana}(X) = \text{moda}(X) = \mu$$



## Otro ejemplo: las densidades gama $\Gamma(\alpha, \lambda)$ (que introdujimos la clase pasada)

$$f_{\alpha, \lambda}(x) = \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x} I_{(0, +\infty)}(x), \quad E(X) = \frac{\alpha}{\lambda}$$



# Cálculo de la moda de las distribuciones gamma $\Gamma(\alpha, \lambda)$

Si  $x > 0$

$$\begin{aligned}f'_{\alpha,\lambda}(x) &= \frac{\lambda^\alpha}{\Gamma(\alpha)} [(\alpha - 1)x^{\alpha-2} e^{-\lambda x} + x^{\alpha-1} (-\lambda)e^{-\lambda x}] \\ &= \frac{\lambda^\alpha}{\Gamma(\alpha)} [(\alpha - 1) - \lambda x] x^{\alpha-2} e^{-\lambda x}\end{aligned}$$

que sólo se anula en

$$x = \frac{\alpha - 1}{\lambda}$$

Entonces vemos que la distribución  $\Gamma(\alpha, \lambda)$  es unimodal, y su moda es

$$\text{moda}(X) = \frac{\alpha - 1}{\lambda}$$

Vemos que en general, para las distribuciones gama, la moda y la esperanza no coinciden.

# ¡En la computadora!

## Cómo calculé los parámetros de posición en Python 3

```
import numpy as np
import scipy.stats
import matplotlib.pyplot as plt
alpha = 5
lambda_ = 1
distribucion = scipy.stats.gamma(a=alpha, scale=1 / lambda_)
media = distribucion.mean()
mediana = distribucion.median()
x = np.arange(start=0, stop=25, step=0.01)
y = distribucion.pdf(x)
plt.plot(x,y)
y_maximo = max(y)
maximo_donde = np.where(y == y_maximo)[0][0]
moda = x[maximo_donde]
```

https:

[//bitbucket.org/pdenapo/programitas-proba/src/main/gama\\_pdf.py](https://bitbucket.org/pdenapo/programitas-proba/src/main/gama_pdf.py)

# La varianza en la distribución normal


En cambio, la varianza

$$\text{Var}(X) = E[(X - \mu_X)^2] = \int_{-\infty}^{\infty} (x - \mu_X)^2 f(x) dx \text{ donde } \mu_X = E[X]$$

y la desviación estándar

$$\sigma_X = \sqrt{\text{Var}(X)}$$

son **parámetros de dispersión**. Veamos por ejemplo la **distribución normal**





# Cambios de variables monótonos

Supongamos que  $X$  es una variable aleatoria con una cierta función de distribución  $F$  como antes, y sea  $Y = \varphi(X)$  donde  $\varphi : \mathbb{R} \rightarrow \mathbb{R}$  es alguna función creciente, biyectiva y con una inversa  $\varphi^{-1} : \mathbb{R} \rightarrow \mathbb{R}$  también creciente.

$$F_Y(y) = P\{Y \leq y\} = P\{\varphi(X) \leq y\} = P\{X \leq \varphi^{-1}(y)\} = F_X(\varphi^{-1}(y))$$

En particular si  $X$  es una variable continua, derivando vemos que

$$f_Y(y) = f_X(\varphi^{-1}(y)) \cdot (\varphi^{-1})'(y) = \frac{1}{\varphi'(x)} f_X(x) \text{ donde } x = \varphi^{-1}(y)$$

El caso más simple e importante, es el de un **cambio de variable lineal** dado por  $\varphi(x) = ax + b$  con  $a > 0$ . Entonces  $\varphi^{-1}(y) = \frac{y-b}{a}$ .  
Luego si  $Y = aX + b$  entonces tenemos que:

$$f_Y(y) = \frac{1}{a} f_X\left(\frac{y-b}{a}\right)$$

# Cambios de variables lineales en la distribución normal

Supongamos que  $X \sim N(\mu, \sigma^2)$  y hagamos un cambio de variable lineal,  $Y = aX + b$  con  $a > 0$  Según la fórmula que dedujimos recién

$$f_Y(y) = \frac{1}{a\sigma\sqrt{2\pi}} \exp \left\{ -\frac{\left(\frac{y-b}{a} - \mu\right)^2}{2\sigma^2} \right\} = \frac{1}{a\sigma\sqrt{2\pi}} \exp \left\{ -\frac{(y - (a\mu + b))^2}{2(a\sigma)^2} \right\}$$

Concluimos que  $Y \sim N(a\mu + b, a^2\sigma^2)$ .


Un caso particular es la estandarización de la normal: Si  $X \sim N(\mu, \sigma^2)$ , entonces

$$X^* = \frac{X - E(X)}{\sqrt{\text{Var}(X)}} = \frac{X - \mu}{\sigma} \sim N(0, 1)$$

# Interpretación de la variancia en la distribución normal

$$\begin{aligned} P\{\mu - \sigma \leq X \leq \mu + \sigma\} &= P\{-1 \leq X^* \leq 1\} \\ &= F_{X^*}(1) - F_{X^*}(-1) \approx 0,6826894921370859 \end{aligned}$$


Es decir que (aproximadamente) el 68,26% de las observaciones cae en esta región.



## Interpretación de la variancia en la distribución normal (2)

$$\begin{aligned} P\{\mu - 2\sigma \leq X \leq \mu + 2\sigma\} &= P\{-2 \leq X^* \leq 2\} \\ &= F_{X^*}(2) - F_{X^*}(-2) \approx 0,9544997361036416 \end{aligned}$$

Es decir que (aproximadamente) el 95,44 % de las obsevaciones cae en esta región.



## Otro ejemplo: la distribución log-normal

Supongamos que  $X \sim N(\mu, \sigma^2)$ . ¿Cuál es la distribución de  $Y = e^X$ ? Tomamos  $\varphi(x) = e^x$ ,  $\varphi : \mathbb{R} \rightarrow \mathbb{R}_{>0}$  es biyectiva y su inversa es  $\varphi^{-1}(y) = \log y$ .  
 $\varphi^{-1} : \mathbb{R}_{>0} \rightarrow \mathbb{R}$ . Recordamos que

$$f_Y(y) = f_X(\varphi^{-1}(y)) \cdot (\varphi^{-1})'(y) = \frac{1}{\varphi'(x)} f_X(x) \text{ donde } x = \varphi^{-1}(y)$$

Como  $\varphi(x) = e^{\log y} = y$ , encontramos que

$$f_Y(y) = \frac{1}{\sigma y \sqrt{2\pi}} \exp\left(-\frac{(\ln y - \mu)^2}{2\sigma^2}\right) \quad y > 0$$

Esta distribución se llama así porque si  $Y$  tiene distribución log-normal, entonces  $\log Y = X$  tiene distribución normal.

# Otra aplicación: esperanza de funciones monótonas de la variable $X$

Como otra aplicación, podemos dar una justificación rigurosa de la fórmula

$$E[\varphi(X)] = \int_{-\infty}^{\infty} \varphi(x) dF_X(x)$$

para el caso en que  $\varphi : \mathbb{R} \rightarrow \mathbb{R}$  es función creciente, biyectiva y con una inversa  $\varphi^{-1} : \mathbb{R} \rightarrow \mathbb{R}$  también creciente

En efecto, en este caso, y llamamos  $Y = \varphi(X)$ , haciendo el cambio de variable  $y = \varphi(x)$  en la integral de Stieltjes y teniendo en cuenta que entonces

$$F_Y(y) = F_X(x) \text{ donde } x = \varphi^{-1}(y)$$

obtenemos que:

$$E[Y] = \int_{-\infty}^{\infty} y dF_Y(y) = \int_{-\infty}^{\infty} \varphi(x) dF_X(x)$$

¡vean qué fáciles son los cambios de variable en la integral de Stieltjes!

# Un ejemplo de un cambio de variable no monótono

La situación es bastante más compleja si admitimos cambios de variables que no son monótonos o biyectivos.

Consideremos por ejemplo el cambio de variable  $Y = X^2$ . Entonces para  $z > 0$  tenemos que:

$$\begin{aligned}F_Y(y) &= P\{X^2 \leq y\} = P\{|X| \leq \sqrt{y}\} = P\{-\sqrt{y} \leq X \leq \sqrt{y}\} = \\ &P\{X \leq \sqrt{y}\} - P\{X < -\sqrt{y}\} = F_X(\sqrt{y}) - F_X(-\sqrt{y}^-)\end{aligned}$$

mientras que claramente  $F_Y(y) = 0$  si  $y < 0$ .

En particular si  $X$  es una variable absolutamente continua con densidad  $f_X$ , encontramos (derivando como antes) que:

$$f_Y(y) = \frac{1}{2\sqrt{y}} [f_X(\sqrt{y}) + f_X(-\sqrt{y})] \quad (y > 0)$$

# Un ejemplo: distribución del cuadrado de una variable normal

Sea  $X \sim N(0, 1)$  una variable aleatoria con distribución normal estándar. Utilizando la fórmula anterior, encontramos que  $Y = X^2$  se distribuye según la densidad

$$f_Y(y) = \frac{1}{2\sqrt{y}} [f_X(\sqrt{y}) + f_X(-\sqrt{y})] = \frac{1}{2\sqrt{y}} \left[ \frac{1}{\sqrt{2\pi}} e^{-y/2} + \frac{1}{\sqrt{2\pi}} e^{-y/2} \right]$$

o sea

$$f_Y(y) = \frac{1}{\sqrt{2\pi}} y^{-1/2} e^{-y/2} \quad (y > 0)$$

Esta densidad se conoce como la densidad  $\chi^2$  (“ji-cuadrado”) con un grado de libertad [abreviada  $\chi_1^2$ ]. Comparando con la definición de las distribuciones gama, y utilizando que  $\Gamma(1/2) = \sqrt{\pi}$ , vemos que coincide con la densidad  $\Gamma\left(\frac{1}{2}, \frac{1}{2}\right)$ .



# Percentiles y Cuartiles

Dado  $k$  con  $0 \leq k \leq 100$  los **percentiles** de la distribución

$$P\{X \leq P_k\} = \frac{k}{100} \text{ o sea } P_k = F^{-1}\left(\frac{k}{100}\right)$$

Tenemos también los **cuartiles**

$$Q_1 = P_{25} = F^{-1}(0,25)$$

$$Q_2 = P_{50} = \text{mediana} = F^{-1}(0,5)$$

$$Q_3 = P_{75} = F^{-1}(0,75)$$

$$\text{iqr} = Q_3 - Q_1$$

Se denomina **rango intercuartílico** o **rango intercuartil**. Es otro **parámetro de dispersión**.

## Ejemplo: Calculemos el rango intercuartílico para una distribución normal (1)

Supongamos que  $X \sim N(\mu, \sigma^2)$ . Recordamos que  $X^* = \frac{X-\mu}{\sigma} \sim N(0, 1)$   
Luego para encontrar los cuartiles, buscamos los de  $X^*$ .

$$P\{X^* \leq Q_1^*\} = 1/4, \text{ o sea } Q_1^* = F_{X^*}^{-1}(0,25)$$

$$P\{X^* \leq Q_3^*\} = 3/4, \text{ o sea } Q_3^* = F_{X^*}^{-1}(0,75)$$

Luego serán

$$Q_1 = \mu + \sigma Q_1^*, Q_3 = \mu + \sigma Q_3^*$$

entonces

$$\text{iqr}(X) = \sigma(Q_3^* - Q_1^*) = \text{iqr}(X^*) \cdot \sigma = k \cdot \sigma$$

donde

$$k \approx 1,3489795003921634$$

# Ejemplo: Calculemos el rango intercuartílico para una distribución normal (2)

## Cómo calculé el rango intercuartílico de una normal estándar

```
from scipy.stats import norm
q1 = norm.ppf(0.25)
q3 = norm.ppf(0.75)
iqr = q3 - q1
print(q1)
print(q3)
print(iqr)
```


## Salida

```
-0.6744897501960817
0.6744897501960817
1.3489795003921634
```

Aquí **ppf** = Percent point function (inversa de la función de distribución), es un método que permite calcular los percentiles de una distribución. 

# Interpretación gráfica

Notamos que  $Q_1^* = -Q_3^*$  por la simetría de la curva normal.



Otra manera de generar distribuciones de probabilidad a partir de otras conocidas es usar **mezclas**, donde primero se realiza un experimento aleatorio, y después dependiendo del resultado del primero, se elige entre varios otros.

Veamos un ejemplo: consideramos un experimento compuesto, donde primero tiramos una moneda equilibrada. Llamamos

$$X = \begin{cases} 1 & \text{si sale cara} \\ 0 & \text{si sale ceca} \end{cases}$$

Y luego según lo que haya salido, elegimos  $Y$  con distribución

$$Y \sim \begin{cases} N(3, 1) & \text{si sale cara} \\ N(-3, 1) & \text{si sale ceca} \end{cases}$$

¿Cuál es la distribución de  $Y$ ?

Consideramos variables  $Y_0, Y_1$  donde  $Y_1 \sim N(3, 1)$  e  $Y_0 \sim N(-3, 1)$ .

## Simulando una mezcla en Python 3

```
import numpy as np
from scipy.stats import norm
y1 = norm(loc=3)
y0 = norm(loc=-3)

rng = np.random.default_rng()

for vez in range(0, 10):
    moneda = rng.integers(0, 2)
    if moneda == 1:
        y = y1.rvs()
    else:
        y = y0.rvs()
    print("moneda=", moneda, "y=", y)
```

## Simular una mezcla (2)

### Ejemplo de salida del programa

```
moneda= 1 y= 1.730389797930093
moneda= 0 y= -2.4864346701853686
moneda= 1 y= 1.848132411942188
moneda= 0 y= -4.041599102041692
moneda= 1 y= 3.9601699112933217
moneda= 0 y= -3.1187137802016913
moneda= 1 y= 2.3693355751812613
moneda= 0 y= -3.3402583893070754
moneda= 0 y= -3.612525955641089
moneda= 1 y= 3.420002649431812
```

## Mezclas (2)

Encontremos la distribución de  $Y$ ,

$$\begin{aligned}F_Y(y) &= P\{Y \leq y\} \\&= P\{Y \leq y/X = 0\} \cdot P\{X = 0\} + P\{Y \leq y/X = 1\} \cdot P\{X = 1\} \\&= \frac{1}{2}F_{Y_0}(y) + \frac{1}{2}F_{Y_1}(y)\end{aligned}$$


donde  $Y_1 \sim N(3, 1)$  e  $Y_0 \sim N(-3, 1)$ . Derivando

$$\begin{aligned}f_Y(y) &= \frac{1}{2}f_{Y_0}(y) + \frac{1}{2}f_{Y_1}(y) \\&= \frac{1}{2} \frac{1}{\sqrt{2\pi}} e^{-(x+3)^2/2} + \frac{1}{2} \frac{1}{\sqrt{2\pi}} e^{-(x-3)^2/2} \\&= \frac{1}{\sqrt{2\pi}} \left[ \frac{1}{2} e^{-(x+3)^2/2} + \frac{1}{2} e^{-(x-3)^2/2} \right]\end{aligned}$$



# Mezclas (3)

$f_Y$  tiene esta forma



Es un ejemplo de una **distribución bimodal**.

# Generalización

Supongamos que primero realizamos un experimento aleatorio que corresponde a una variable aleatoria  $X$  con valores

$$x_1, x_2, \dots, x_k$$

una cierta distribución discreta

$$P\{X = x_i\} = p_i$$

y luego, dependiendo del valor de  $X$  elegimos realizar otros experimentos que corresponden a las variables aleatorias

$$Y_1, Y_2, \dots, Y_k$$

con las correspondientes densidades de probabilidad  $f_{Y_i}$ . Si en el primer experimento resulta que  $X = x_i$ , tomamos  $Y = Y_i$ .

## Generalización (2)

Entonces por la fórmula de probabilidad total

$$\begin{aligned}F_Y(y) &= P\{Y \leq y\} = \sum_{i=1}^k P\{Y \leq y/X = x_i\} \cdot P\{X = x_i\} \\ &= \sum_{i=1}^k F_{Y_i}(y) \cdot p_i\end{aligned}$$

Derivando obtendremos:

$$f_Y(y) = \sum_{i=1}^k f_{Y_i}(y) \cdot p_i$$

Esta distribución es una **mezcla** de las  $f_{Y_i}$  utilizando los pesos  $p_i$  que dan la distribución de  $X$ .