

Áreas bajo curvas y distribuciones de probabilidad con WxMaxima

Si X es una variable aleatoria, y $f(x)$ su función de probabilidad (o densidad), entonces

$$\text{Prob}(X \in [a, b]) = \int_a^b f(x) dx,$$

que corresponde con el área bajo la curva $f(x)$ cuando $x \in [a, b]$.

En Estadística se utilizan varias distribuciones de probabilidad, siendo las más frecuentes

- **Distribución normal estándar**, $X \sim N(0, 1)$

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}, \quad x \in \mathbb{R}$$

- **Distribución normal general (de media μ y DT σ)**, $X \sim N(\mu, \sigma)$

$$f_{\mu, \sigma}(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-(\frac{x-\mu}{\sigma})^2/2}, \quad x \in \mathbb{R}$$

- **Distribución t-Student de grado m** , $X \sim T_m$

$$f_m(x) = \frac{c_m}{(1 + \frac{x^2}{m})^{\frac{m+1}{2}}}, \quad x \in \mathbb{R},$$

donde la constante $c_m > 0$ es tal que $\int_{-\infty}^{\infty} f_m(x) dx = 1$.

En **WxMaxima**, el paquete `distrib` contiene estas y otras distribuciones

`load(distrib)`

Los comandos más usuales (para normales y t-Student) son los siguientes

- Función de densidad $f(x)$

$$\text{pdf_normal}(x, 0, 1), \quad \text{pdf_normal}(x, \mu, \sigma), \quad \text{pdf_student_t}(x, m)$$

- Función de densidad acumulada: $F(x) = \text{Prob}(X \leq x) = \int_{-\infty}^x f(y) dy$

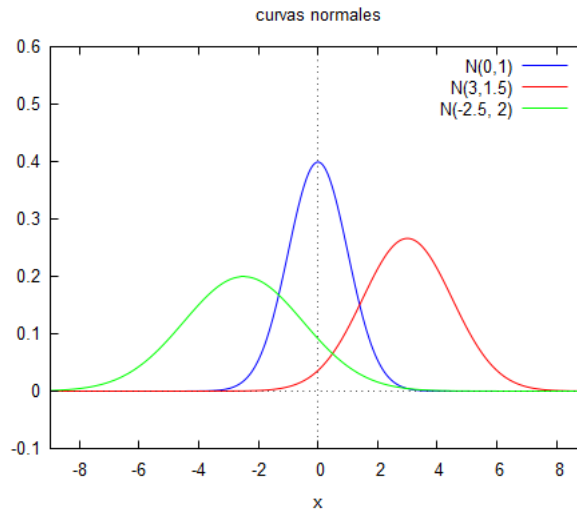
$$\text{cdf_normal}(x, \mu, \sigma), \quad \text{cdf_student_t}(x, m)$$

- Percentil- α : es el número x_α que cumple $\text{Prob}(X \leq x_\alpha) = \int_{-\infty}^{x_\alpha} f(y) dy = \alpha$

$$\text{quantile_normal}(\alpha, \mu, \sigma), \quad \text{quantile_student_t}(\alpha, m)$$

Ejemplo 1: Dibuja las curvas normales $N(0, 1)$, $N(3, 1'5)$, $N(-2'5, 2)$

```
(%i1) load(distrib);
(%i2) N(x,mu,sigma):= pdf_normal(x,mu,sigma);
(%i3) wxplot2d([N(x,0,1),N(x,3,1.5), N(x,-2.5,2)], [x,-9,9], [y, -.1,.6],
               [legend, "N(0,1)", "N(3,1.5)", "N(-2.5, 2)"],
               [title, "curvas normales"]);
```



Ejemplo 2: Para la distribución normal $X \sim N(0, 1)$, calcula las probabilidades

$$\text{Prob}(X \leq 2), \quad \text{Prob}(-1 \leq X \leq 1), \quad \text{Prob}(X \geq 0'5)$$

```
(%i1) load(distrib); numer:true
(%i2) cdf_normal(2,0,1);
      cdf_normal(1,0,1) - cdf_normal(-1,0,1);
      1-cdf_normal(0.5,0,1);

      (% o2) 0.9772498680518208
      (% o3) 0.6826894921370859
      (% o4) 0.3085375387259869
```

Ejemplo 3: Para la distribución t -Student T_6 , calcula los percentiles cuando

$$\alpha = 0'30 \qquad \alpha = 0'975 \qquad \alpha = 0'995$$

```
(%i1) load(distrib); numer:true
(%i2) quantile_student_t(0.30, 6);
      quantile_student_t(0.975, 6);
      quantile_student_t(0.995, 6);

      (% o2) -0.553380923551519
      (% o3) 2.446911851144877
      (% o4) 3.707428021260888
```

Cálculo de intervalos de confianza

Cuando $X \sim N(\mu, \sigma)$, y el valor de μ es desconocido, es posible estimarlo a partir de una muestra aleatoria $\{x_1, \dots, x_n\}$ de X . El estimador habitual es la media muestral

$$\hat{\mu} = \bar{x} = \frac{x_1 + \dots + x_n}{n}$$

Sin embargo, esta elección de $\hat{\mu}$ cambia con la muestra...

¿Es posible dar un intervalo $\bar{x} \pm \text{error}$, que podamos afirmar que contiene el valor real de μ con una *confianza del 95%*?

La respuesta es positiva, si $\{x_1, \dots, x_n\}$ es una muestra aleatoria *independiente*. Para ello se utilizan los percentiles

$$z_\alpha = \text{quantile_normal}(\alpha, 0, 1), \quad t_\alpha^{(m)} = \text{quantile_student_t}(\alpha, m)$$

Caso 1: $X \sim N(\mu, \sigma)$, con σ conocido. Entonces $Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$, y se cumple

$$\text{Prob} \left(-z_{\frac{1+\alpha}{2}} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq z_{\frac{1+\alpha}{2}} \right) = \alpha.$$

En particular, si $\alpha = 0'95$,

$$\boxed{\bar{x} \pm z_{0,975} \frac{\sigma}{\sqrt{n}}}$$

es un *intervalo de confianza para μ al 95%*.

Caso 2: Si σ es desconocido, entonces debemos estimarlo con la *desviación típica muestral*

$$\hat{\sigma} = s_n = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

En ese caso, $T = \frac{\bar{X} - \mu}{s_n/\sqrt{n}} \sim T_{n-1}$, y se cumple

$$\text{Prob} \left(-t_{\frac{1+\alpha}{2}}^{(n-1)} \leq \frac{\bar{X} - \mu}{s_n/\sqrt{n}} \leq t_{\frac{1+\alpha}{2}}^{(n-1)} \right) = \alpha.$$

En particular, si $\alpha = 0'95$,

$$\boxed{\bar{x} \pm t_{0,975}^{(n-1)} \frac{s_n}{\sqrt{n}}}$$

es un *intervalo de confianza para μ al 95%*.

Ejemplo 1: La cantidad de Na en un medicamento se distribuye como una normal con $\sigma = 0'6$, y μ a determinar. Extraemos una muestra de $n = 36$ pastillas al azar y obtenemos

$$\bar{x} = 2'2$$

Encontrar intervalos de confianza para μ al 95% y al 99%. Si el fabricante afirma que sus pastillas tienen $\mu = 2'5$, ¿podría tener razón?

Solución: Utilizando WxMaxima obtenemos

1. Intervalo al 95%

$$\bar{x} \pm z_{0,975} \frac{\sigma}{\sqrt{n}} = 2'2 \pm 1'96 \cdot \frac{0'6}{\sqrt{36}} \approx 2'2 \pm 0'2 = [2, 2'4]$$

2. Intervalo al 99%

$$\bar{x} \pm z_{0,995} \frac{\sigma}{\sqrt{n}} = 2'2 \pm 2'58 \cdot \frac{0'6}{\sqrt{36}} \approx 2'2 \pm 0'26 = [1'94, 2'46]$$

En particular, con un 99% de confianza podemos garantizar que el fabricante **no** tiene razón cuando afirma que sus pastillas tienen $\mu = 2'5$.

Ejemplo 2: La concentración de flúor en la pasta de dientes sigue una distribución $N(\mu, \sigma)$. La normativa exige que para uso infantil no se superen las 400 ppm de Fl. Un inspector extrae $n = 15$ muestras aleatorias de un fabricante, y obtiene

$$\bar{x} = 425, \quad s_n = 30$$

Encontrar intervalos de confianza para μ al 95% y al 99%. ¿Tiene el inspector evidencia suficiente para afirmar que se superan los 400 ppm de Fl?

Solución: Como μ, σ son ambos desconocidos, utilizamos intervalos con la t -Student

1. Intervalo al 95%

$$\bar{x} \pm t_{0,975}^{(14)} \frac{s_n}{\sqrt{n}} = 425 \pm 2'145 \cdot \frac{30}{\sqrt{15}} \approx 425 \pm 16'6 \approx [408, 442]$$

2. Intervalo al 99%

$$\bar{x} \pm t_{0,995}^{(14)} \frac{s_n}{\sqrt{n}} = 425 \pm 2'977 \cdot \frac{30}{\sqrt{15}} \approx 425 \pm 23 \approx [402, 448].$$

En particular, con un 99% de confianza podemos garantizar que para esa pasta de dientes μ supera la cantidad de 400 ppm.

Ejemplo 3: Para obtener bandera azul en una playa, la concentración de *E. Coli* debe ser inferior a 500 UFC/100 ml. La concentración en muestras aleatorias se comporta como una $N(\mu, \sigma)$. Un inspector toma $n = 8$ muestras y obtiene

$$\bar{x} = 515, \quad s_n = 20$$

Encontrar un intervalo de confianza para μ al 95%. El Ayuntamiento afirma que $\mu = 500$. ¿Tiene el inspector evidencia suficiente para rechazar la bandera azul?

Solución: De nuevo utilizamos intervalos con la t -Student

1. Intervalo al 95% para μ

$$\bar{x} \pm t_{0,975}^{(7)} \frac{s_n}{\sqrt{n}} = 515 \pm 2'365 \cdot \frac{20}{\sqrt{8}} \approx 515 \pm 16'72 \approx [498, 532]$$

Como 500 pertenece al intervalo, no tenemos evidencia suficiente (al 95%) para concluir que el Ayuntamiento no tenga razón. Por tanto, debemos mantener la bandera azul.