

Tema 5. MODELOS DE DISTRIBUCIONES CONTINUOS.

Objetivos

Conceptos:

- ✚ Conocer los siguientes modelos continuos de probabilidad: uniforme, normal, exponencial, gamma y Pareto. De cada uno de ellos:
 - * Tipo de experimentos que modelizan
 - * Función de densidad
 - * Esperanza y varianza
 - * Propiedades gráficas y de asimetría
 - * Propiedades de reproductividad (suma de v.a.)
- ✚ Conocer y comprender el Teorema Central del Límite

Saber hacer:

- ✚ Dada una variable **aleatoria continua**:
 - * Reconocer si sigue algún modelo de probabilidad
 - * Calcular probabilidades, utilizando las tablas o bien a partir de las fórmulas adecuadas
 - * Hallar esperanza y varianza.
- ✚ Hallar probabilidades para una variable con distribución normal utilizando las tablas de $N(0,1)$
- ✚ Utilizar el TCL para poder calcular, mediante la normal, probabilidades de diversas v.a. (sumas de otras v.a independientes o medias aritméticas de dichas v.a.)
- ✚ Dada una variable **estadística continua**:
 - * Estudiar si se ajusta a alguno de los modelos de probabilidad estudiados
 - * Determinar los parámetros correspondientes a dicho modelo

Problemas de exámenes (web):

SIN: Diciembre 2005: Problema 2 (d)
Septiembre 2005. Problema 2
Septiembre 2004: Problema 2
Febrero 2003: Problema 2
Junio 2003: Problema 2 A

CON: Diciembre 2005: (b) (modelos A y B)
Junio 2006: (f)

5.1.- Introducción.

Al igual que en el caso discreto, hay situaciones que siguen modelos de distribución continua muy similares.

- Errores de redondeo, truncamiento
- Medidas de una característica de una población: estatura, peso, notas, ...
- Tiempo de vida de seres vivos, instrumentos, ...

Recordamos que los modelos son **simplificaciones** de la realidad, no se ajustan exactamente a ella, pero nos sirven para poder comprenderla mejor.

Además, veremos que uno de estos modelos, el modelo normal, se relaciona con todos los demás. Bajo determinadas condiciones, **la suma de v.a. de cualquier modelo tenderá a parecerse al modelo normal.**

5.2.- Distribución uniforme continua.

Modelo	Uniforme continua U(a,b)	
Tipo de experimento	X: toma valores en un intervalo [a,b] de tal forma que subintervalos de igual amplitud tienen la misma probabilidad	
Ejemplos	1) X: Errores cometidos al redondear a un decimal un resultado $X \sim U(-0.05, 0.05)$ 2) Y: Tiempo de espera en una parada de autobús o metro que viene con una frecuencia de 10 minutos $Y \sim U(0, 10)$	
Función de densidad	$f(x) = \frac{1}{b-a}$, si $x \in [a, b]$; 0 en el resto.	
$E(X) = \frac{a+b}{2}$	$V(X) = \frac{(b-a)^2}{12}$	CAF=0 (simétrica)
Uniform Distribution 		

Ejemplo:

Sabemos que un autobús pasa cada 10 minutos. Hallar la probabilidad de esperar menos de 2 minutos, el tiempo medio de espera y la desviación típica del tiempo de espera.

Sea Y: Tiempo de espera en la parada del autobús

Como el autobús pasa cada 10 minutos y no sabemos cuánto tiempo hace que ha pasado, nada nos indica que sea más probable esperar un tiempo u otro, por lo que Y sigue un modelo uniforme: $Y \sim U(0,10)$ (0 es el tiempo mínimo de espera y 10 el tiempo máximo de espera)

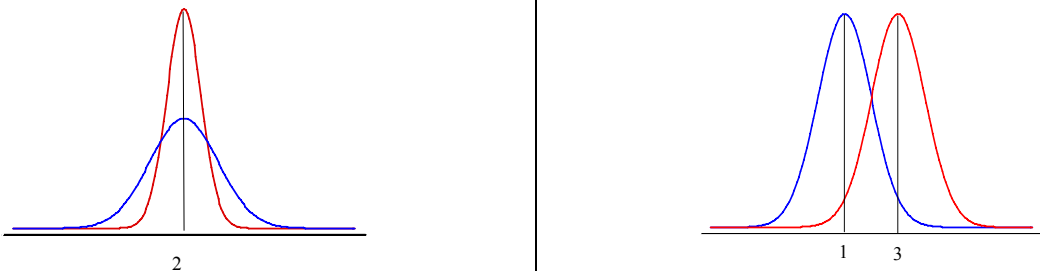
Su función de densidad será $f(x) = \frac{1}{10-0} = \frac{1}{10}$ si $0 < x < 10$; 0 en el resto .

La probabilidad de esperar menos de 2 minutos, será $P(Y < 2) = \int_{-\infty}^2 f(x)dx = \int_0^2 \frac{1}{10}dx = 0.2$

El tiempo medio de espera será $E(Y) = \frac{0+10}{2} = 5$ minutos.

La desviación típica: $dt = \sqrt{V(Y)} = \sqrt{\frac{(10-0)^2}{12}} = \frac{10}{\sqrt{12}} = 2.89$ minutos.

5.3.- Distribución normal.

Modelo	Normal $N(\mu, \sigma)$		
Tipo de experimento	X: medida de variables físicas: tamaños, temperaturas, errores, ... X: suma de gran número de experimentos independientes \approx Normal (aunque es discreta, se puede aproximar por una normal)		
Ejemplos	1) Estatura de una población 2) Número de cafés vendidos en una semana en una cafetería \approx Normal		
Función de densidad	$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, \quad \forall x \in \mathbb{R}$		
	$E(X) = \mu$	$V(X) = \sigma^2 ; dt(X) = \sigma$	$CAF = 0 : \text{simétrica}$
			
	<p>Igual media, distintas desviaciones típicas</p> <p>Distintas medias, igual desviación típica</p>		

Cálculo de probabilidades de la normal

Estandarización de la normal:

Si $X \sim N(\mu, \sigma)$, entonces $\frac{X - \mu}{\sigma} \sim N(0,1)$ ¹. Notación: $Z \sim N(0,1)$.

Cálculo de probabilidades:

Si $X \sim N(\mu, \sigma)$, entonces:

$$P(a < X < b) = P\left(\frac{a - \mu}{\sigma} < \frac{X - \mu}{\sigma} < \frac{b - \mu}{\sigma}\right) = P\left(\frac{a - \mu}{\sigma} < Z < \frac{b - \mu}{\sigma}\right), \text{ con } Z \sim N(0,1)$$

Tablas de Z:


Da los valores de $P(Z < a)$ con $a > 0$.

Para el resto de los casos:

- $P(Z > a) = 1 - P(Z < a)$

Por la simetría de la normal:

- $P(Z < -a) = P(Z > a) = 1 - P(Z < a)$
- $P(Z > -a) = P(Z < a)$



Ejemplo:

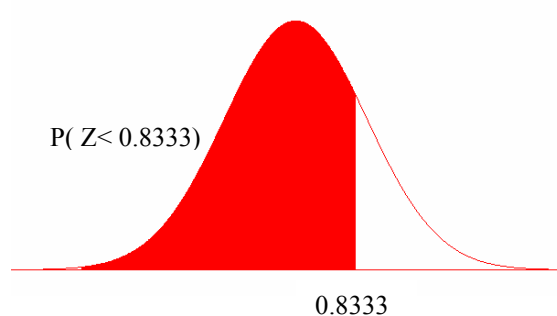
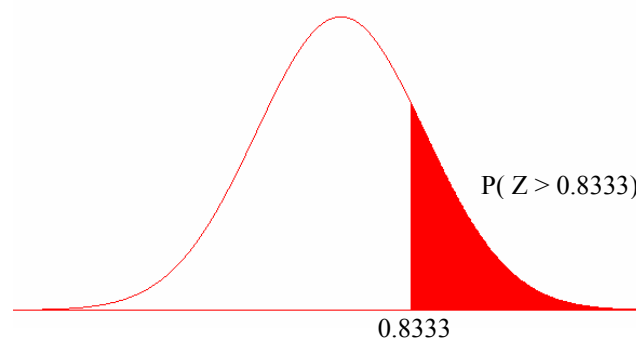
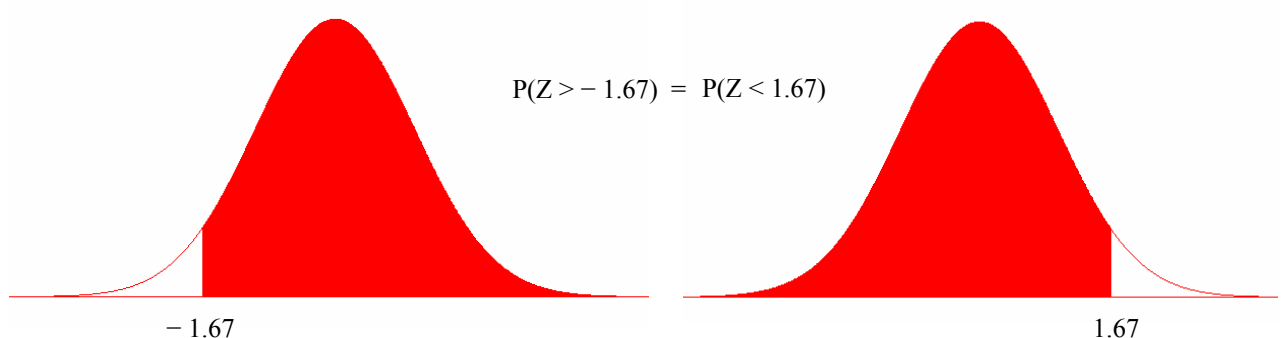
X: Estatura de los alumnos de Estadística, y suponemos $X \approx N(175,6)$ ².


¹ Si $X \sim N(\mu, \sigma)$, $E(X) = \mu$, $V(X) = \sigma^2$. Por tanto:

$$E\left(\frac{X - \mu}{\sigma}\right) = \frac{1}{\sigma}(E(X) - E(\mu)) = \frac{1}{\sigma}(\mu - \mu) = 0, \text{ y } V\left(\frac{X - \mu}{\sigma}\right) = \frac{1}{\sigma^2}(V(X) + V(\mu)) = \frac{1}{\sigma^2}(\sigma^2 + 0) = 1$$

² Ejemplo: Estatura de alumnos del GM23

<p>Density Trace for Estatura</p> <p>A line graph showing a normal distribution curve. The x-axis is labeled 'Estatura' and ranges from 160 to 190. The y-axis is labeled 'density' and ranges from 0 to 0.06. The curve peaks at approximately 175 with a density of about 0.055.</p>	<p>Histogram for Estatura</p> <p>A histogram with pink bars representing the frequency of heights. The x-axis is labeled 'Estatura' and ranges from 160 to 200. The y-axis is labeled 'frequency' and ranges from 0 to 16. A blue normal distribution curve is overlaid on the histogram, peaking at a frequency of about 16 around the value 175.</p>
<p>Fitted normal distribution: mean = 174.615 standard deviation = 6.24338</p>	<p>Approximate P-Value = 0.66543 > 0.3</p> <p>Aceptamos que sigue una distribución normal</p>

<p>Probabilidad de medir menos de 180:</p> $P(X < 180) = P\left(Z < \frac{180-175}{6}\right) = P(Z < 0.8333)$ <p>Tablas:</p> $P(X < 180) = 0.7967$	 <p>A normal distribution curve with the area to the left of the vertical line at $z = 0.8333$ shaded in red. The label $P(Z < 0.8333)$ is placed to the left of the curve.</p>
<p>Probabilidad de medir más de 180:</p> $P(X > 180) = P\left(Z > \frac{180-175}{6}\right) = P(Z > 0.8333)$ <p>Tablas:</p> $P(X > 180) = 1 - P(Z < 0.83) = 1 - 0.7967 = 0.2033$	 <p>A normal distribution curve with the area to the right of the vertical line at $z = 0.8333$ shaded in red. The label $P(Z > 0.8333)$ is placed to the right of the curve.</p>
<p>Probabilidad de medir más de 165:</p> $P(X > 165) = P\left(Z > \frac{165-175}{6}\right) = P(Z > -1.67) ; \text{ Tablas: } P(Z > -1.67) = P(Z < 1.67) = 0.9525$  <p>Two normal distribution curves are shown side-by-side. The left curve has the area to the right of the vertical line at $z = -1.67$ shaded in red. The right curve has the area to the left of the vertical line at $z = 1.67$ shaded in red. The two shaded areas are shown to be equal. The text $P(Z > -1.67) = P(Z < 1.67)$ is centered between the two curves.</p>	
<p>Probabilidad de medir menos de 165:</p> $P(X < 165) = P\left(Z > \frac{165-175}{6}\right) = P(Z < -1.67) ;$ <p>Tablas: $P(Z < -1.67) = P(Z > 1.67) = 1 - P(Z < 1.67) = 1 - 0.9525 = 0.0475$</p>	




Probabilidad de medir entre 165 y 180:

$$P(165 < X < 180) = P\left(\frac{165-175}{6} < Z < \frac{180-175}{6}\right) = P(-1.67 < Z < 0.8333)$$

Tablas:

$$P(Z < 0.83) - P(Z < -1.67) = P(Z < 0.83) - (1 - P(Z < 1.67)) = 0.7967 - (1 - 0.9525) = 0.7492$$



Otras propiedades de la normal son:

Reproductividad de la normal:

Si X e Y son v.a. **independientes** tales que $X \sim N(\mu_X, \sigma_X)$, $Y \sim N(\mu_Y, \sigma_Y)$. Entonces:

- i) $\mathbf{X+Y} \sim N(\mu_X + \mu_Y, \sqrt{\sigma_X^2 + \sigma_Y^2})$.³
- ii) $\mathbf{kX} \sim N(k\mu_X, |k|\sigma_X)$.⁴

Ejemplos:

Si X e Y son v.a. **independientes** tales que $X \sim N(2,5)$, $Y \sim N(-3,1)$. Entonces:

- i) $\mathbf{X+Y} \sim N(2-3, \sqrt{5^2 + 1^2}) = N(-1, \sqrt{6})$.
- ii) $\mathbf{(-4)X} \sim N(-8, 20)$.

³ $E(X+Y) = E(X) + E(Y) = \mu_X + \mu_Y$; por la independencia $V(X+Y) = V(X) + V(Y) = \sigma_X^2 + \sigma_Y^2$.

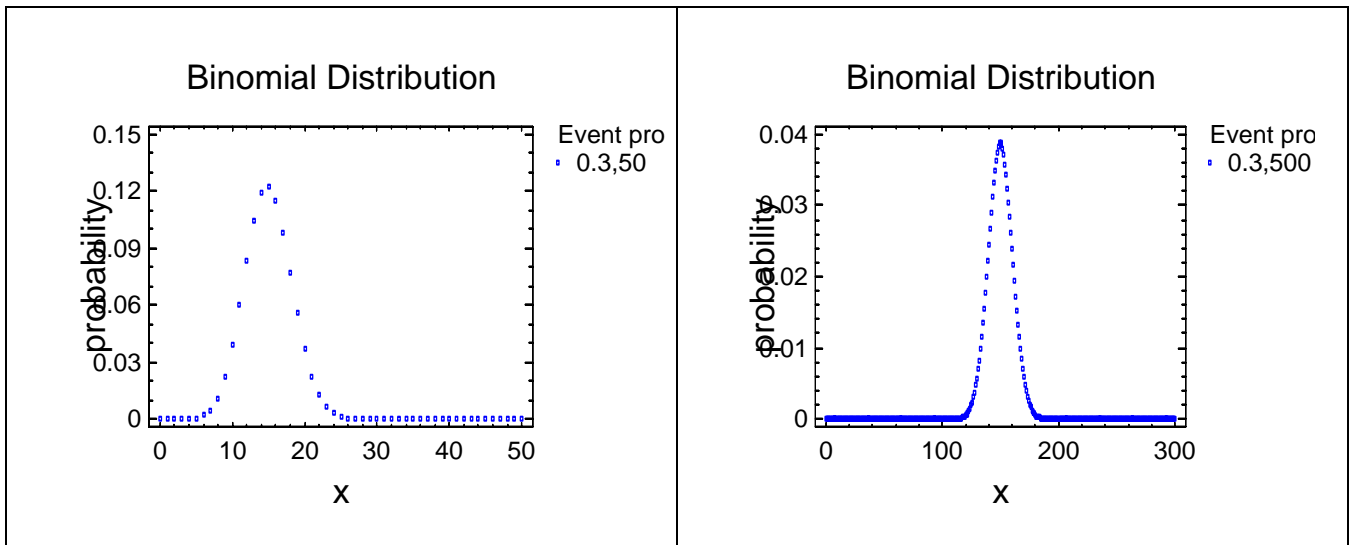
⁴ $E(kX) = kE(X) = k\mu_X$; $V(kX) = k^2V(X) = k^2\sigma_X^2 \Rightarrow \sqrt{V(kX)} = \sqrt{k^2\sigma_X^2} = |k|\sigma_X$.

5.4.- Teorema Central del Límite.

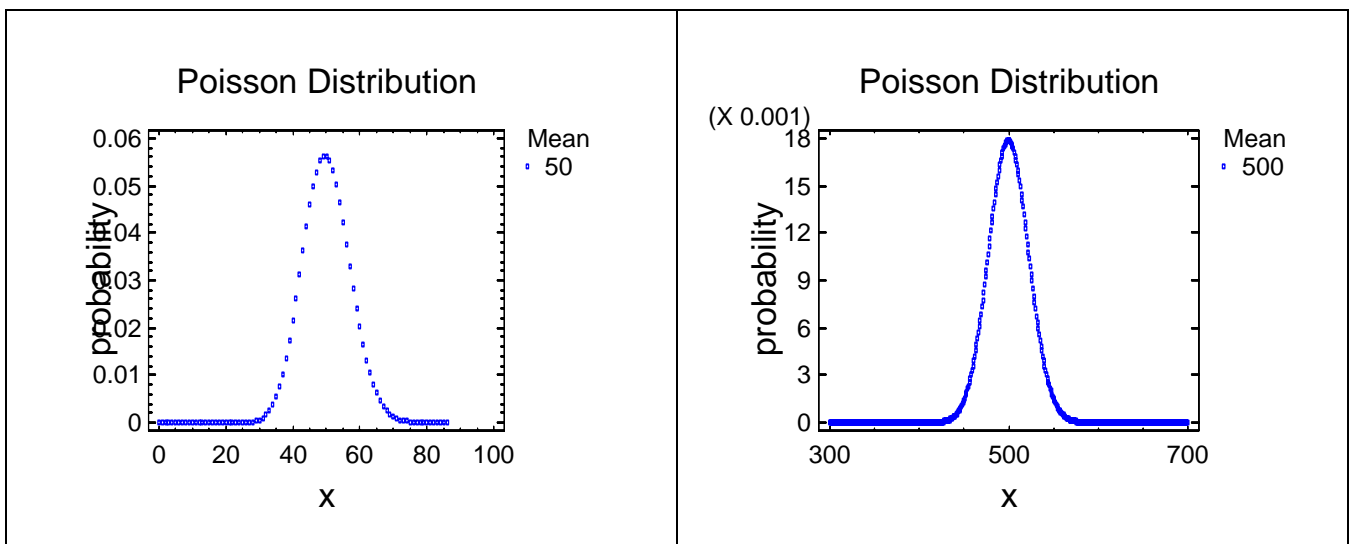
Acabamos de ver que la suma de normales es otra distribución normal de media la media de la suma y varianza la varianza de la suma.

En determinadas condiciones, la **suma de v.a.** cualesquiera se podrá **aproximar por una distribución normal** de media la media de la suma y varianza la varianza de la suma.

Hemos visto en el tema anterior que si $X \sim B(n,p)$, se puede expresar como $X=X_1+\dots+X_n$ siendo $X_i \sim B(1,p)$ v.a. **independientes**. Si **n** es **suficientemente grande** observamos que la distribución de probabilidad se asemeja a la de la normal:



Algo análogo ocurre con el modelo de Poisson. Si $X \sim P(n)$, se puede expresar como $X=X_1+\dots+X_n$ siendo $X_i \sim P(1)$ v.a. **independientes**. Si **n** es **suficientemente grande** observamos que la distribución de probabilidad también se asemeja a la de la normal:



¿Ocurre esto con otros modelos de distribución? ¿En qué condiciones?

Teorema Central del Límite. (TCL)

Sean X_1, \dots, X_n v.a.i.i.d. (variables aleatorias **independientes con idéntica distribución**). Entonces, **cuando** $n \rightarrow +\infty$, la distribución de $Y = X_1 + \dots + X_n$ se puede aproximar por una distribución normal:

$$Y = X_1 + \dots + X_n \approx N(E(Y), \sqrt{V(Y)}), \quad \text{o bien} \quad \frac{Y - E(Y)}{\sqrt{V(Y)}} \approx N(0,1)$$

Si denotamos $E(X_i) = \mu$ y $V(X_i) = \sigma^2$, se tiene que:

- $X_1 + \dots + X_n \approx N(n\mu, \sigma\sqrt{n})$ ⁵
- $\frac{X_1 + \dots + X_n}{n} \approx N\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$ ⁶

NOTA: En general, se considera válido el TCL si $n \geq 100$.

Ejemplos:

Sea X : tiempo diario (horas) viendo la televisión, cuyo modelo de distribución no se conoce, pero sí se conoce $E(X) = 2$ y $V(X) = 9$.

a) Hallar la probabilidad de que al cabo de un año una persona haya visto la televisión durante más de 600 horas.

Si definimos Y : tiempo de televisión al cabo de un año, nos piden $P(Y > 600)$.

Como Y se puede expresar como $Y = X_1 + \dots + X_{365}$. Suponiendo independencia entre los días, como $n = 365 > 100$, se tiene que:

$$Y \sim N(365 \cdot 2, 3\sqrt{365})$$

$$\text{Por tanto, } P(Y > 600) = P\left(\frac{Y - 730}{3\sqrt{365}} > \frac{600 - 730}{3\sqrt{365}}\right) = P(Z > -2.27), \text{ siendo } Z \sim N(0,1).$$

Buscando en las tablas, $P(Y > 600) = P(Z > -2.27) = P(Z < 2.27) = 0.9884$.

b) Hallar la probabilidad de que, eligiendo una persona al azar, el tiempo medio diario que dedica a ver la televisión a lo largo de un año sea menor que hora y media.

Si definimos M : tiempo medio de televisión diaria al cabo de un año, nos piden $P(M < 1.5)$.

M se puede expresar como $M = \frac{X_1 + \dots + X_{365}}{365}$. Suponiendo independencia entre los días, como $n = 365 > 100$, se puede aplicar TCL y se tiene que:

$$^5 E(Y) = E(X_1 + \dots + X_n) = \mu + \dots + \mu = n\mu$$

$$V(Y) = V(X_1 + \dots + X_n) = \sigma^2 + \dots + \sigma^2 = n\sigma^2 \Rightarrow \sigma_Y = \sqrt{n\sigma^2} = \sigma\sqrt{n} \text{ (es fundamental la independencia)}$$

$$^6 E\left(\frac{X_1 + \dots + X_n}{n}\right) = \frac{1}{n}(E(X_1) + \dots + E(X_n)) = \frac{1}{n}(\mu + \dots + \mu) = \frac{1}{n}(n\mu) = \mu$$

$$V\left(\frac{X_1 + \dots + X_n}{n}\right) = \frac{1}{n^2}(V(X_1) + \dots + V(X_n)) = \frac{1}{n^2}(\sigma^2 + \dots + \sigma^2) = \frac{1}{n^2}(n\sigma^2) = \frac{\sigma^2}{n} \Rightarrow \sigma_Y = \frac{\sigma}{\sqrt{n}}$$

$$M \sim N\left(2, \frac{3}{\sqrt{365}}\right)$$

$$\text{Por tanto, } P(M < 1.5) = P\left(\frac{M-2}{\frac{3}{\sqrt{365}}} < \frac{1.5-2}{\frac{3}{\sqrt{365}}}\right) = P(Z < -9.55) \approx 0.$$

Casos particulares:

- Si $X \sim P(\lambda)$, consideraremos que $\mathbf{X} \approx N(\lambda, \sqrt{\lambda})$ si $\lambda > 10$.
- Si $X \sim B(n, p)$, consideraremos que $\mathbf{X} \approx N(np, \sqrt{np(1-p)})$
 - si $n \geq 50$ y $0.1 < p < 0.9$.
 - si $n \geq 50$, $p \leq 0.1$ y $np > 10$ (⁷).
 - si $n \geq 50$, $p \geq 0.9$ y $n(1-p) > 10$ (⁸).

Ejemplos:

- Si $X \sim B(75, 0.3)$, se verifica que $\mathbf{X} \approx N(22.5, \sqrt{75 \cdot 0.3 \cdot 0.7}) = N(22.5, 3.97)$.
- Sea Y: Número de cafés vendidos en una semana en una cafetería

Por su definición, es una v.a. discreta ("número de"), que seguirá un modelo de Poisson: número de "éxitos" (cafés vendidos) en un intervalo (semana). Si el número medio de cafés vendidos en una semana es de 10000, tendríamos $Y \sim P(10000)$.

Se verifica que $\mathbf{X} \approx N(10000, \sqrt{10000}) = N(10000, 100)$.

(Por la reproductividad de la Poisson, podríamos suponer que $Y = Y_1 + \dots + Y_{100}$, siendo Y_i = número de cafés vendidos en media hora. El TCL, nos asegura que podemos aproximar Y por una normal.)

Para calcular probabilidades, conviene tener en cuenta que Y es discreta (probabilidad en puntos) y que la normal es continua (probabilidad en intervalos). En general, se asocia

$$P(Y=r) \approx P(r-0.5 < N < r+0.5)$$

Si queremos hallar la probabilidad de vender en una semana 10500, o más, cafés:

$$P(Y \geq 10500) \approx P(N > 10499.5) = P\left(\frac{N-10000}{100} > \frac{10499.5-10000}{100}\right) = P(Z > 4.995) \approx 0$$

⁷ Recordad que si $n \geq 50$, $p \leq 0.1$ y $np \leq 10$, $X \sim B(n, p)$ se puede aproximar por $\mathbf{X} \approx P(np)$ (tema 4, pg 7)

⁸ Si si $n \geq 50$, $p \geq 0.9$ y $n(1-p) \leq 10$, se trabaja con $Y \sim B(n, 1-p)$, que se puede aproximar por $\mathbf{Y} \approx P(n(1-p))$.

5.5.- Distribución gamma. Distribución exponencial.

Modelo	Exponencial $\text{Exp}(\beta)$	
Tipo de experimento	X: tiempo transcurrido hasta que ocurre un suceso de Poisson (β : número medio de sucesos de Poisson por unidad de tiempo) X: tiempo de "funcionamiento" de "algo" (en el caso de que el "fallo" no depende del tiempo que lleva "funcionando")	
Ejemplos	1) Tiempo (en minutos) transcurrido hasta recibir el primer e-mail del día. 2) Tiempo transcurrido entre la llegada de un cliente y la llegada del siguiente 3) Tiempo de servicio a un cliente	
Función de densidad	$f(x) = \beta e^{-\beta x}$, si $x > 0$, 0 en el resto.	
$E(X) = \frac{1}{\beta}$		$V(X) = \frac{1}{\beta^2}$
Simetría: $CAF = 2 > 0$: simetría a la derecha.		
Si el número de mensajes de correo-e que recibimos en un minuto sigue una distribución de Poisson de media $\beta = 0.1$, entonces X: Tiempo (en minutos) transcurrido hasta recibir el primer e-mail del día, sigue una distribución exponencial con $\beta = 0.1$. $E(X) = \frac{1}{\beta} = 10$ (el tiempo esperado hasta recibir el primer e-mail es de 10 minutos)	Si nos dicen que X: Tiempo (en minutos) transcurrido hasta recibir el primer e-mail del día, sigue una distribución exponencial de media medio minuto, entonces: $E(X) = \frac{1}{\beta} = \frac{1}{2} \Rightarrow \beta = 2$. Por tanto $X \sim \text{exp}(2)$	
Exponential Distribution 	Exponential Distribution 	

Otras propiedades:

La distribución exponencial no tiene memoria:

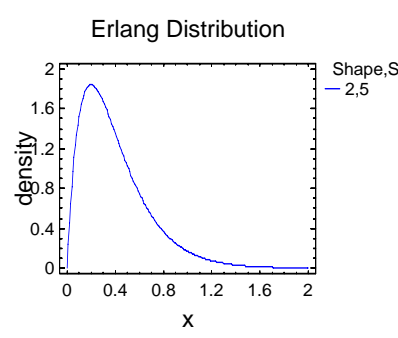
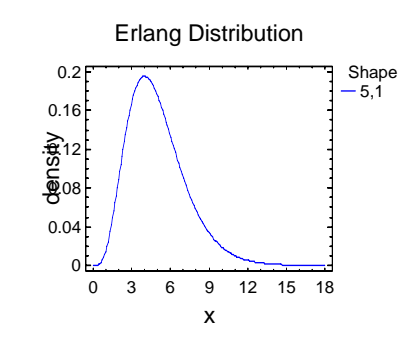
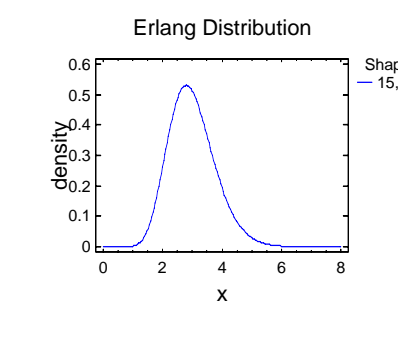
$$P(X \leq t+h | X > h) = P(X \leq t)$$

Ejemplo: Sea X es el tiempo empleado en encontrar una plaza de aparcamiento; si llevamos media hora de búsqueda infructuosa, la probabilidad de encontrar aparcamiento en los próximos 10 minutos es la misma que haberlo encontrado en menos de 10 minutos desde que empezamos a buscar:

$$P(X \leq 40 | X > 30) = \frac{\int_{30}^{40} \beta e^{-\beta x} dx}{\int_{30}^{+\infty} \beta e^{-\beta x} dx} = \frac{-e^{-40\beta} + e^{-30\beta}}{e^{-30\beta}} = -e^{-10\beta} + 1$$
$$P(X \leq 10) = \int_0^{10} \beta e^{-\beta x} dx = 1 - e^{-10\beta}$$

Reproductividad de la exponencial:

Si X_1, \dots, X_n son n v.a. independientes con $X_i \sim \exp(\beta)$, entonces $X_1 + \dots + X_n \sim E(n, \beta)$ (modelo que estudiaremos a continuación)

Modelo	Erlang $E(n, \beta)$		
Tipo de experimento	X: tiempo transcurrido hasta que suceden n sucesos de Poisson X: tiempo de vida de "algo" (Si $n=1$, es el modelo exponencial.)		
Ejemplos	1) Tiempo transcurrido hasta que falla un sistema que depende del funcionamiento de un determinado número de dispositivos,		
Función de densidad	$f(x) = \frac{\beta^n}{(n-1)!} e^{-\beta x} x^{n-1}, \text{ si } x > 0, \text{ 0 en el resto.}$		
	$E(X) = \frac{n}{\beta}$	$V(X) = \frac{n}{\beta^2}$	
Simetría	$CAF = \frac{2}{\sqrt{n}} > 0$: asimetría a la derecha. Cuanto mayor es n , la distribución es más simétrica.		
	 <p style="text-align: center;">E(2,5)</p>	 <p style="text-align: center;">E(5,1)</p>	 <p style="text-align: center;">E(15,5)</p>
Otras propiedades	<p>Reproductividad de la Erlang: Si X e Y son v.a. independientes tales que $X \sim E(n, \beta)$, $Y \sim E(m, \beta)$ entonces $X+Y \sim E(n+m, \beta)$.</p> <p>Si n es suficientemente grande $E(n, \beta) \approx N\left(\frac{n}{\beta}, \frac{\sqrt{n}}{\beta}\right)$ (TCL)</p>		

El modelo que generaliza al modelo exponencial y al modelo Erlang es el modelo gamma:

Modelo	Gamma $\gamma(\alpha, \beta)$	
Tipo de experimento	X: duración de "algo"	
Ejemplos	Duración de una llamada telefónica	
Función de densidad	$f(x) = \frac{\beta^\alpha}{\Gamma(\alpha)} e^{-\beta x} x^{\alpha-1}, \text{ si } x > 0, \text{ 0 en el resto.}$ <p>(Definición: $\Gamma(\alpha) = \int_0^\infty e^{-x} x^{\alpha-1} dx$; si $\alpha = n \in \mathbb{N}$, $\Gamma(n) = (n-1)!$)</p> <p>(Si $\alpha = 1$, es el caso exponencial $\exp(\beta)$; si $\alpha = n \in \mathbb{N}$, es el caso Erlang $E(n, \beta)$)</p>	
	$E(X) = \frac{\alpha}{\beta}$	$V(X) = \frac{\alpha}{\beta^2}$
Simetría	$CAF = \frac{2}{\sqrt{\alpha}} > 0$: asimetría a la derecha.	
α es el parámetro que determina la forma (shape) (Cuanto mayor es α , mayor simetría):		
Alfa < 1	Alfa = 1	Alfa > 1
β es el parámetro que determina la escala (scale) :		
Beta= 0.1	Beta= 10	
Otras propiedades	<p><i>Reproductividad de la Gamma:</i></p> <p>Si X e Y son v.a. independientes tales que $X \sim \gamma(\alpha_x, \beta)$, $Y \sim \gamma(\alpha_y, \beta)$ entonces $X+Y \sim \gamma(\alpha_x + \alpha_y, \beta)$.</p> <p>Si α es suficientemente grande $\gamma(\alpha, \beta) \approx N\left(\frac{\alpha}{\beta}, \frac{\sqrt{\alpha}}{\beta}\right)$ (TCL)</p>	

5.6.- Otras distribuciones continuas.

Modelo	Pareto $P(\alpha, k)$	
Tipo de experimento	X: tiempo de duración de "algo", sabiendo que dicho tiempo es superior a k X: cantidad de "algo", sabiendo que dicha cantidad es superior a k	
Ejemplos	1) Tiempo en ser procesado un mensaje en un servidor web 2) Coste de una llamada telefónica, sabiendo que el primer minuto se paga siempre completo y es un precio fijo	
Función de densidad	$f(x) = \alpha k^\alpha x^{-(\alpha+1)}$, si $x \geq k$, 0 en el resto. ($\alpha, k > 0$)	
	$E(X) = \frac{\alpha k}{\alpha - 1}$, si $\alpha > 1$; $E(X) = \infty$ si $\alpha \leq 1$	$V(X) = \frac{\alpha k^2}{(\alpha - 2)(\alpha - 1)^2}$ si $\alpha > 2$; $V(X) = \infty$ si $\alpha \leq 2$
Simetría	$CAF > 0$: simetría a la derecha ("cola pesada": más "densa" que en otros modelos; exponencial, por ejemplo)	
<div style="display: flex; justify-content: space-around;"> <div style="text-align: center;"> <p>Pareto Distribution Shape — 0.5</p> </div> <div style="text-align: center;"> <p>Pareto Distribution Shape — 5</p> </div> </div>		

Ejemplos:

1) Sea X: Tiempo (en segundos) en ser procesado un mensaje en un servidor web, $X \sim P(3,2)$ ($\alpha=3, k=2$)

La función de densidad será: $f(x) = 3 \cdot 2^3 x^{-4}$, si $x \geq 2$.

La probabilidad de que un mensaje tarde más de 5 segundos en ser procesado será:

$$P(X \geq 5) = \int_5^{+\infty} 3 \cdot 2^3 x^{-4} dx = 0.064$$

El tiempo medio en ser procesado un mensaje es de 3 segundos:

$$E(X) = \int_2^{+\infty} x(3 \cdot 2^3 x^{-4}) dx = \int_2^{+\infty} \frac{24}{x^3} dx = 3 \quad \text{o bien} \quad E(X) = \frac{3 \cdot 2}{3-1} = 3.$$

Ajuste de una variable estadística a un modelo teórico

Objetivo:

- elegir un modelo
- encontrar los parámetros del modelo

Medios:

- definición de la variable: ¿qué mide? ¿en qué condiciones?
- medidas descriptivas (media, varianza, simetrías, frecuencias, ...)
- representaciones gráficas


Verificación:

Contrastes no paramétricos con Statgraphics (Distribution Fitting):
 p-valor > 0.3 para aceptar la hipótesis
 (cuanto mayor sea, con más confianza se acepta el modelo propuesto)

Ejemplo:

X4: Número de llamadas diarias que se hacen por teléfono móvil
 (Datos tomados en el curso 2004/05)

- Como la variable mide número de "éxitos" (llamadas) en un intervalo de tiempo (un día), eso nos hace pensar en un modelo de Poisson.
- Como $E(X)=1.25$ y $V(X)=1.51$, que son valores más o menos similares, sería posible un modelo de Poisson de parámetro $\lambda=1.25$ (la media). (Con esos datos, sería menos posible un modelo binomial, pues en dicho modelo la varianza siempre es menor que la media)
- Observamos la representación gráfica del diagrama de barras (asimetría a la derecha) y lo comparamos con la distribución de probabilidad de la $P(1.25)$, y vemos que son similares.



Por tanto, la hipótesis que tendríamos que verificar es si $X4 \sim P(1.25)$.

Utilizando la opción de Statgraphics Describe/Distributios/Distribution Fitting, y seleccionando la opción del modelo Poisson, obtenemos:

Goodness-of-Fit Tests for Llamadas diarias :
 Fitted Poisson distribution:
 mean = 1.25641

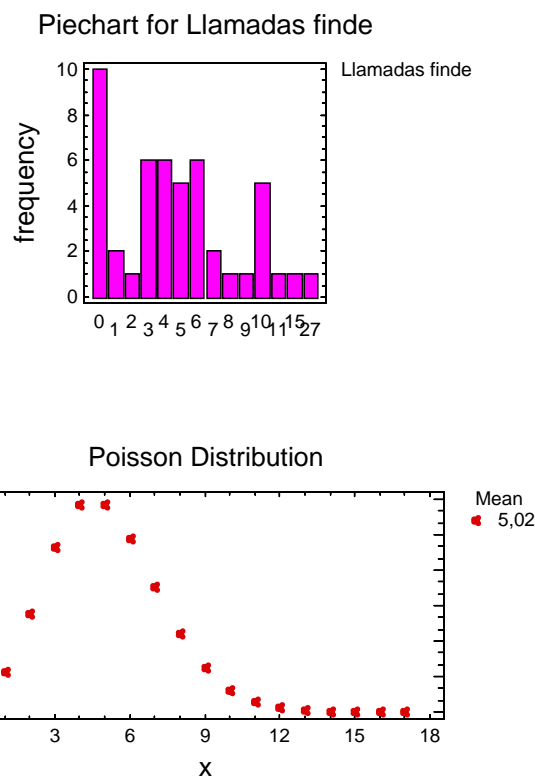
Chi-Square = 0.555238 with 2 d.f. P-Value = 0.757586

Como $p\text{-valor}=0.75 > 0.3$, aceptamos que la variable *número de llamadas diarias*, puede tener una distribución de Poisson de parámetro $\lambda=1.25$.

Si consideramos la variable Y: Número de llamadas que se hacen por teléfono móvil en un fin de semana, considerando los datos del curso 2006/07, tenemos lo siguiente:

- Como la variable mide número de "éxitos" (llamadas) en un intervalo de tiempo (fin de semana), eso nos hace pensar en un modelo de Poisson.
- Como $E(X)=5.02$ y $V(X)=23.5$, que son valores muy dispares, esto nos indica que difícilmente sigue un modelo de Poisson.
- La representación gráfica del diagrama de barras y la de la distribución de probabilidad de la $P(5)$, no se parecen.

Por tanto, no es muy probable que siga un modelo de Poisson. Esto se corrobora utilizando la opción de Statgraphics Describe/Distributivos/Distribution Fitting, y seleccionando la opción del modelo Poisson, obtenemos $P\text{-Value} = 0,000567705 < 0.3$, por lo que rechazamos la idea de que la variable Y siga un modelo de Poisson.



Ejercicios:

Con los datos recogidos en este curso, estudiar si siguen algún modelo de distribución discreta las siguientes variables (<http://www.eui.upm.es/~rafami/Estadistica/Material/material07.html>):

- N° de asignaturas matriculadas
- N° de asignaturas aprobadas
- N° de asignaturas aprobadas habiéndose matriculado de 11 asignaturas
- N° de asignaturas aprobadas habiéndose presentado a 10 asignaturas