



DISTRIBUCIONES DE PROBABILIDAD

PROF. MAGDIEL ABLAN BORTONE

PROF. PAOLO RAMONI PERAZZI



FACULTAD DE INGENIERÍA

UNIVERSIDAD DE LOS ANDES



- Modelos probabilísticos discretos
 - Distribución binomial
 - Distribución geométrica
 - Distribución binomial negativa
 - Distribución de Poisson
- Modelos probabilísticos continuos
 - Distribución uniforme
 - Distribución exponencial
 - Otras distribuciones (Pareto, Weibull, Gamma)
 - Distribución normal



- Son las llamadas distribuciones de conteo
- Se usan para modelizar la frecuencia de los eventos y el tiempo de espera en el caso discreto
- Muchas de las distribuciones más importantes se definen tomando en cuenta las pruebas o ensayos de Bernoulli



- Experimento aleatorio con sólo dos resultados posibles, tradicionalmente denominados **éxito** y **fracaso**

- Una VA X es Bernoulli si

$$p(0) = P(X = 0) = 1 - p$$

$$p(1) = P(X = 1) = p$$

- Donde p es la probabilidad de éxito y $0 < p < 1$
- $E[X] = p$ y $Var[X] = p(1-p)$



- Sea X el número de éxitos en n ensayos de Bernoulli, independientes e idénticamente distribuidos, con probabilidad de éxito p , se dice que $X \sim bin(n,p)$ tal que $P(X = i) = p(i)$ es:

$$p(i) = \binom{n}{i} p^i (1-p)^{n-i} \quad i = 0, 1, \dots, n$$

- Donde $\binom{n}{i} = \frac{n!}{(n-i)!i!}$
- $E[X] = np$ y $Var[X] = np(1-p)$



- Ejemplo: entrecruzar flores rojas y blancas produce 25% de flores rojas
- Cruzamos cinco pares de flores rojas y blancos y producen cinco descendientes
- ¿Cuál es la p que no se obtengan hijos rojos?

$$\begin{aligned} P(X = 0) &= \frac{5!}{(5 - 0)! 0!} p^0 (1 - p)^5 \\ &= 1(0.25)^0 (0.75)^5 = 0.237 \end{aligned}$$

```
>dbinom(0, 5, 0.25)
```



- ¿Cuál es la probabilidad que se obtengan menos de dos hijos rojos?

$$P(X < 2) = P(X = 0) + P(X = 1)$$

$$\frac{5!}{(5-0)!0!} 0.25^0 (1-0.25)^5 + \frac{5!}{(5-1)!1!} 0.25^1 (1-0.25)^4$$

$$= 0.237 + 0.395 = 0.632$$

```
>pbinom(1, 5, 0.25)
```

Distribución binomial



```
> par(mfrow=c(2,2))
> plot(0:10,dbinom(0:10,10,0.5),type="h",xlab="x",ylab="P(X=x)",ylim=c(0,1),main="binomial(10,0.5)")
> points(0:10,dbinom(0:10,10,0.5),pch=1)

> plot(0:20,dbinom(0:20,20,0.5),type="h",xlab="x",ylab="P(X=x)",ylim=c(0,1),main="binomial(20,0.5)")
> points(0:20,dbinom(0:20,20,0.5),pch=1)

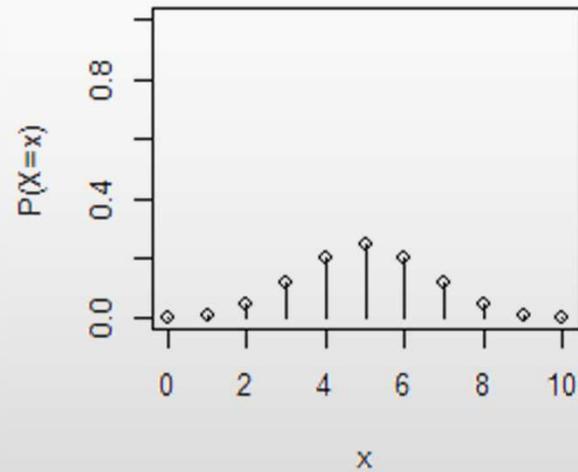
> plot(0:10,dbinom(0:10,10,0.2),type="h",xlab="x",ylab="P(X=x)",ylim=c(0,1),main="binomial(10,0.2)")
> points(0:10,dbinom(0:10,10,0.2),pch=1)

> plot(0:10,dbinom(0:10,10,0.8),type="h",xlab="x",ylab="P(X=x)",ylim=c(0,1),main="binomial(10,0.8)")
> points(0:10,dbinom(0:10,10,0.8),pch=1)
```

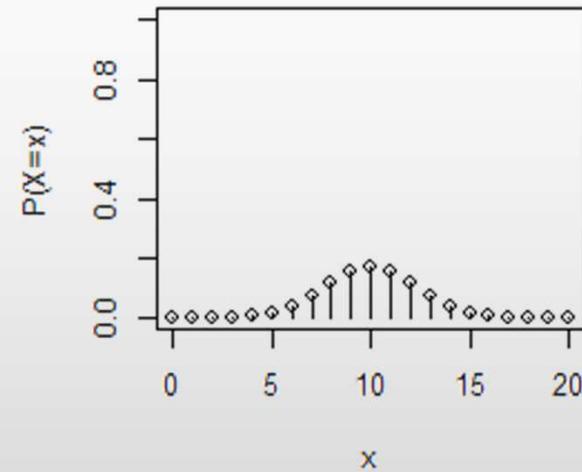
Distribución binomial



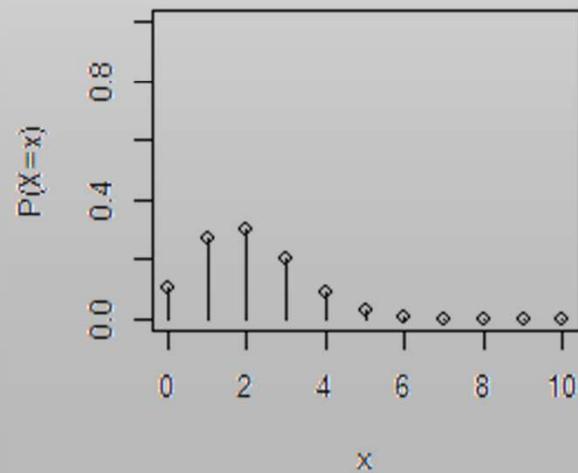
binomial(10,0.5)



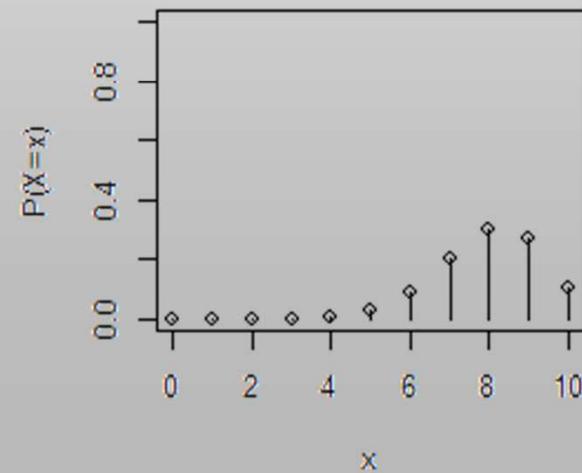
binomial(20,0.5)



binomial(10,0.2)



binomial(10,0.8)





- Otro ejemplo: se lanzan cuatro monedas justas. Los resultados se presumen independientes. ¿Cuál es la p de obtener dos caras y dos sellos?
- X es el número de caras (éxitos)
- Parámetros $n = 4$ y $p = 1/2$
- ¿ $P(X=2)$?

```
>dbinom( 2 , 4 , 0.5 )
```

```
[1] 0.375
```



- Considere una secuencia de ensayos de Bernoulli con probabilidad de éxito p . se define la VA X como el número de fallas hasta observar el primer éxito. entonces:

$$P(X = x) = p(1 - p)^x, x = 0, 1, 2, \dots$$

- Y se denota como $X \sim geom(p)$
- $E[X] = (1-p)/p$ y $Var[X] = (1-p)/p^2$
- Ojo: algunas veces se define como el número de ensayos hasta obtener el primer éxito, Así:

$$P(X = x) = p(1 - p)^{x-1}, x = 1, 2, 3, \dots$$

Distribución geométrica



```
> opar<-par(mfrow=c(2,2))
> plot(0:20,dgeom(0:20,0.2),type="h",xlab="x",ylab="P
(X=x)",ylim=c(0,1),main="geométrica(0.2)")
> points(0:20,dgeom(0:20,0.2),pch=1)

> plot(0:20,dgeom(0:20,0.4),type="h",xlab="x",ylab="P
(X=x)",ylim=c(0,1),main="geométrica(0.4)")
> points(0:20,dgeom(0:20,0.4),pch=1)

> plot(0:20,dgeom(0:20,0.6),type="h",xlab="x",ylab="P
(X=x)",ylim=c(0,1),main="geométrica(0.6)")
> points(0:20,dgeom(0:20,0.6),pch=1)

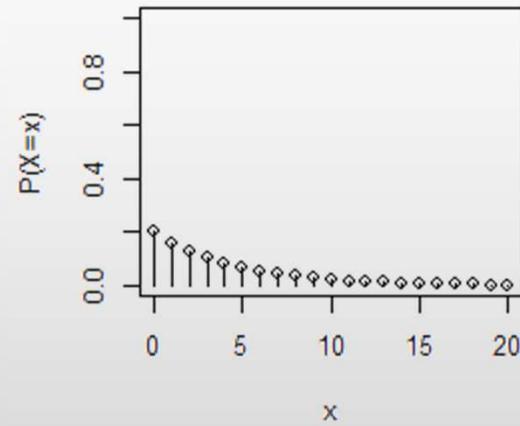
> plot(0:20,dgeom(0:20,0.8),type="h",xlab="x",ylab="P
(X=x)",ylim=c(0,1),main="geométrica(0.8)")
> points(0:20,dgeom(0:20,0.8),pch=1)
> par(opar)
```

Distribución geométrica

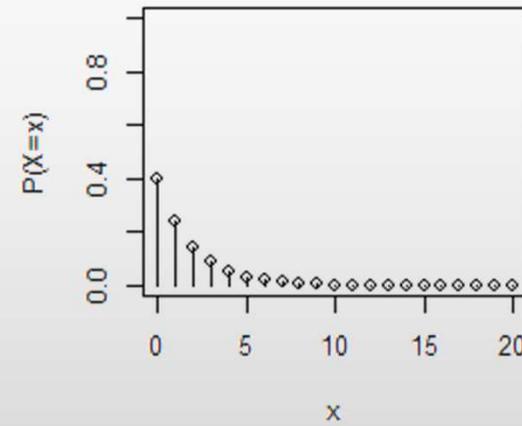


Postgrado en Modelado y Simulación

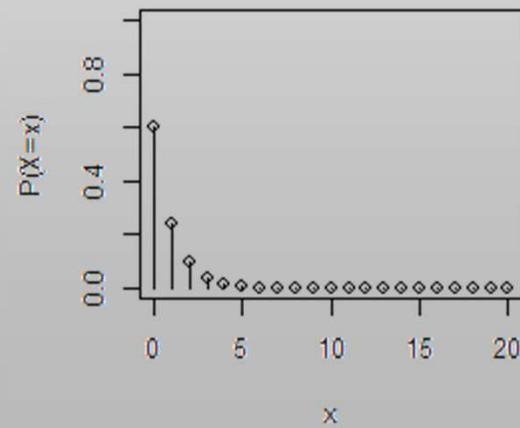
geométrica(0.2)



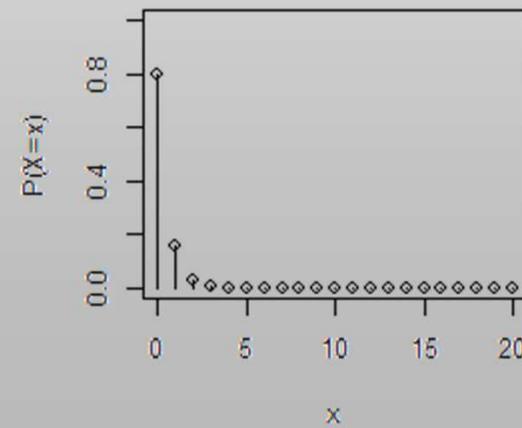
geométrica(0.4)



geométrica(0.6)



geométrica(0.8)





- Ejemplo, está tratando de encender una parrilla con fósforos en un día con mucho viento. Cada fósforo tiene una p de encender la parrilla de 0.1 pero sólo hay 4. ¿Cuál es la p que encienda la parrilla antes de quedarse sin fósforos?
- Suponga que tiene una cantidad ilimitada de fósforos y sea X el número de intentos fallidos antes de encender la parrilla.
- Entonces $X \sim geom(p=0.1)$ y se pide calcular $P(X \leq 3) = p_{geom}(3, 0.1) = 0.3439$



- Ahora suponga que si se usan dos fósforos al mismo tiempo, la p de encendido es 0.3
- ¿Es una buena idea usar los dos fósforos al mismo tiempo?
- Sea Y la VA que representa el número de intentos fallidos hasta encender la parrilla usando dos fósforos a la vez
- Si $P(Y \leq 1)$ es más grande que $P(X \leq 3)$ valdrá la pena usar dos fósforos en vez de uno



- Sea Z el número de fallas hasta obtener el r -ésimo éxito en una secuencia de ensayos de Bernoulli independientes
- Se dice entonces que $Z \sim \text{negbin}(r,p)$ y su función de masa de probabilidad está dada por:

$$P(Z = z) = \binom{r + z - 1}{r - 1} p^r (1 - p)^z \quad \text{para } z = 0, 1, \dots$$

- $E[Z] = r(1-p)/p$ y $\text{Var}[Z] = r(1-p)/p^2$
- Igual que la geométrica, a veces se define como el número de ensayos y cambia la expresión de probabilidad

Distribución binomial negativa



Postgrado en Modelado y Simulación

```
> par(mfrow=c(2,2))
> plot(0:20,dnbinom(0:20,2,0.5),type="h",xlab="x",ylab="P(X
=x)",ylim=c(0,1),main="Binomial negativa(2,0.5)")
> points(0:20,dnbinom(0:20,2,0.5),pch=1)

> plot(0:20,dnbinom(0:20,3,0.5),type="h",xlab="x",ylab="P(X
=x)",ylim=c(0,1),main="Binomial negativa(3,0.5)")
> points(0:20,dnbinom(0:20,3,0.5),pch=1)

> plot(0:20,dnbinom(0:20,10,0.5),type="h",xlab="x",ylab="P(
X=x)",ylim=c(0,1),main="Binomial negativa(10,0.5)")
> points(0:20,dnbinom(0:20,10,0.5),pch=1)

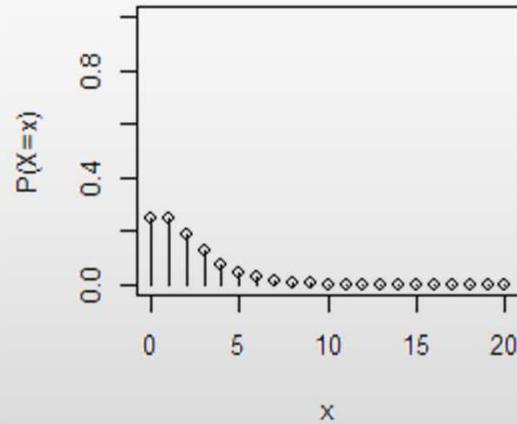
> plot(0:20,dnbinom(0:20,10,0.8),type="h",xlab="x",ylab="P(
X=x)",ylim=c(0,1),main="Binomial negativa(10,0.8)")
> points(0:20,dnbinom(0:20,10,0.8),pch=1)
```

Distribución binomial negativa

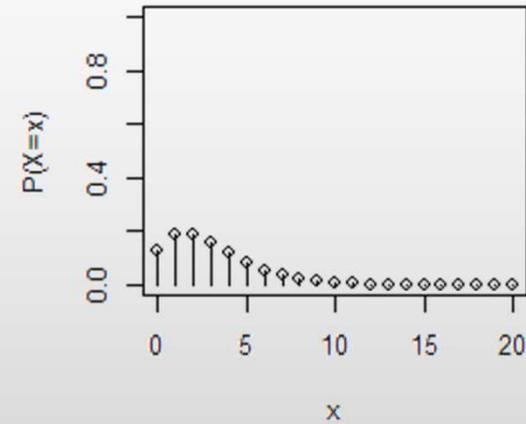


Postgrado en Modelado y Simulación

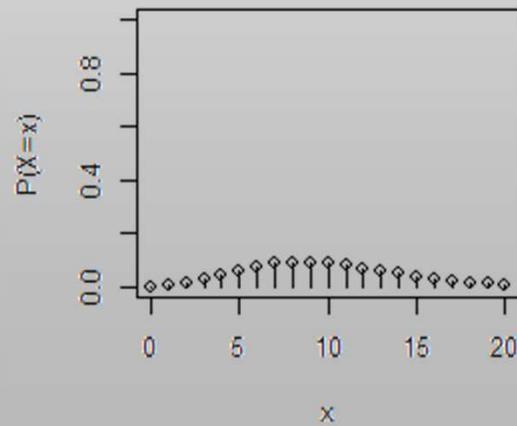
Binomial negativa(2,0.5)



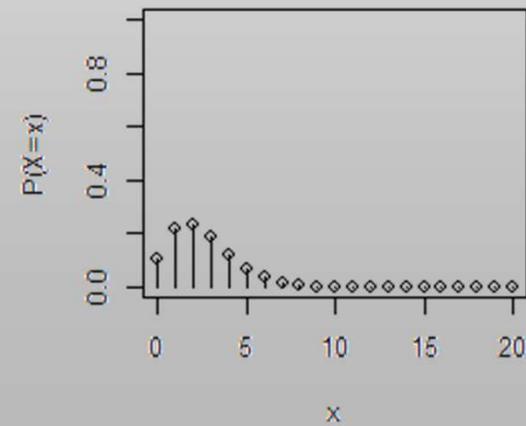
Binomial negativa(3,0.5)



Binomial negativa(10,0.5)



Binomial negativa(10,0.8)





- Un fabricante prueba la calidad de su producto seleccionando al azar una muestra de tamaño 100 de cada lote
- Si hay más de dos artículos defectuosos, la producción se detiene para solucionar el problema
- Cada artículo es defectuoso con independencia de los otros con probabilidad $p = 0.01$
- En la práctica, los artículos en la muestra se prueban secuencialmente.



- El procedimiento se para cuando se consiguen tres artículos defectuosos.
- Sea Z el número de artículos observados antes de conseguir tres artículos defectuosos. Entonces $Z \sim \text{negbin}(3, 0.01)$
- ¿Cuál es la p de que se pare la producción?
- $P(\text{parar la producción}) = p(Z + 3 \leq 100) = p(z \leq 97)$

```
>pnbinom(97, 3, 0.01)
```

```
[1] 0.0793732
```



- X tiene distribución de Poisson con parámetro λ ,
 $X \sim pois(\lambda)$ si:

$$P(X = x) = \frac{e^{-\lambda} \lambda^x}{x!} \quad x = 0, 1, \dots$$

$$E[x] = \lambda \quad \text{y} \quad Var[x] = \lambda$$

- La distribución de Poisson se usa como modelo para eventos raros y eventos que ocurren al azar a una tasa constante en el tiempo o el espacio.



- Los ejemplos clásicos incluyen al número de accidentes en un año, el número de llamadas que llegan a una central telefónica en una hora dada, el número de carros que llegan a una intersección dada, entre otros.

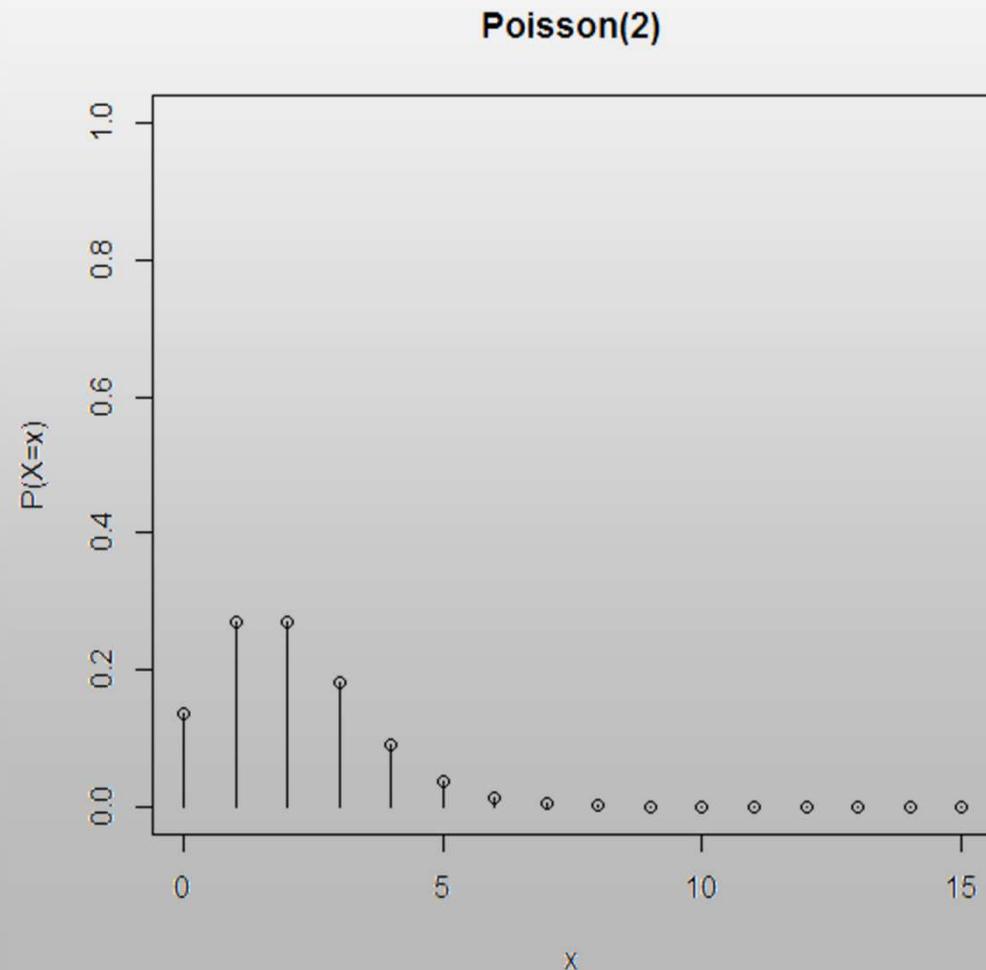


- Ejemplo: el n medio de accidentes ocurridos en un planta petrolera es 2 accidentes en 2 meses
 1. ¿Qué modelo sigue la variable n de accidentes ocurridos en la planta por 2 meses?
 2. ¿Cuál es la p que haya más de 2 accidentes en 2 meses?
 3. ¿Cuál que haya entre 2 y 8 inclusive, en 2 meses?
 4. ¿Cuál que haya más de 2 en 1 mes?



1. Es razonable pensar que sigue una distribución de Poisson de parámetro $\lambda = E[X] = 2$

```
plot(0:15,dpois(0:15,2),type="h",  
     xlab="x",ylab="P(X=x)",ylim=c(0,1),  
     main="Poisson(2) ")  
points(0:15,dpois(0:15,2),pch=1)
```





$$2. \quad P(X > 2) = 1 - P(X \leq 2) = 1 - 0.6767 = 0.3233$$

> 1-ppois(2, 2)

$$3. \quad P(2 \leq X \leq 8) = P(X \leq 8) - P(X \leq 1) = 0.999 - 0.406 = 0.5938$$

> ppois(8, 2) - ppois(1, 2)

$$4. \quad Y \sim \text{pois}(1)$$

$$P(Y > 2) = 1 - P(Y \leq 2) = 1 - 0.9197 = 0.0803$$

> 1-ppois(2, 1)



- El n de errores tipográficos en una página dada de estas láminas se distribuye como una Poisson de parámetro $\lambda=1$. ¿Cuál es la probabilidad de conseguir uno o más errores? Es decir $P(X \geq 1)$
- Estas expresiones en R son equivalentes y arrojan el valor correcto [1] 0.633

```
>ppois(0,1,lower.tail=F)
```

```
>1- ppois(0,1)
```

```
>dpois(0,1)
```

Distribución de Poisson



```
> par(mfrow=c(2,2))

> plot(0:15,dpois(0:15,0.5),type="h",xlab="x",ylab="P
  (X=x)",ylim=c(0,1),main="Poisson(0.5)")
> points(0:15,dpois(0:15,0.5),pch=1)

> plot(0:15,dpois(0:15,1),type="h",xlab="x",ylab="P(X
  =x)",ylim=c(0,1),main="Poisson(1)")
> points(0:15,dpois(0:15,1),pch=1)

> plot(0:15,dpois(0:15,2),type="h",xlab="x",ylab="P(X
  =x)",ylim=c(0,1),main="Poisson(2)")
> points(0:15,dpois(0:15,2),pch=1)

> plot(0:15,dpois(0:15,5),type="h",xlab="x",ylab="P(X
  =x)",ylim=c(0,1),main="Poisson(5)")
> points(0:15,dpois(0:15,5),pch=1)
```

Distribución de Poisson



```
> par(mfrow=c(2,2))

> plot(0:15,dpois(0:15,0.5),type="h",xlab="x",ylab="P
  (X=x)",ylim=c(0,1),main="Poisson(0.5)")
> points(0:15,dpois(0:15,0.5),pch=1)

> plot(0:15,dpois(0:15,1),type="h",xlab="x",ylab="P(X
  =x)",ylim=c(0,1),main="Poisson(1)")
> points(0:15,dpois(0:15,1),pch=1)

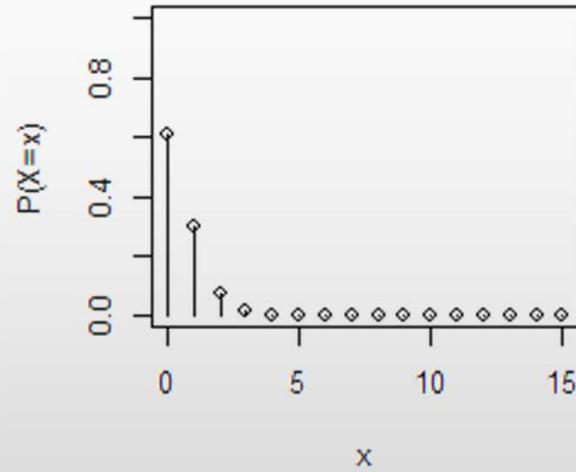
> plot(0:15,dpois(0:15,2),type="h",xlab="x",ylab="P(X
  =x)",ylim=c(0,1),main="Poisson(2)")
> points(0:15,dpois(0:15,2),pch=1)

> plot(0:15,dpois(0:15,5),type="h",xlab="x",ylab="P(X
  =x)",ylim=c(0,1),main="Poisson(5)")
> points(0:15,dpois(0:15,5),pch=1)
```

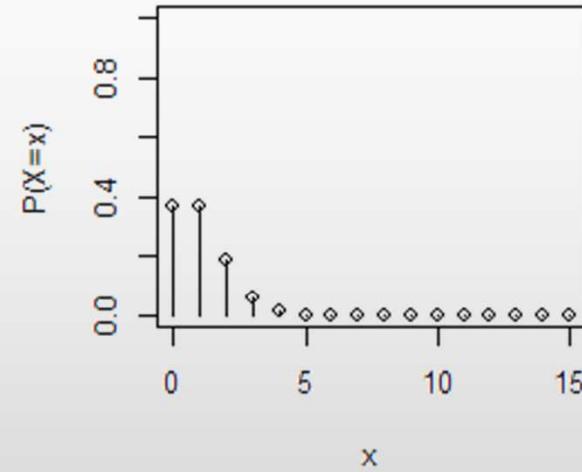
Distribución de Poisson



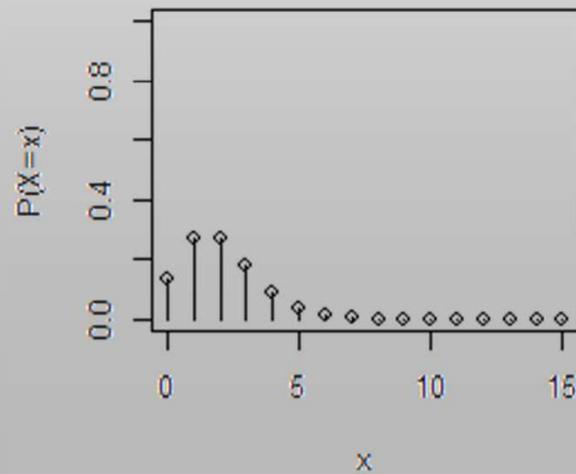
Poisson(0.5)



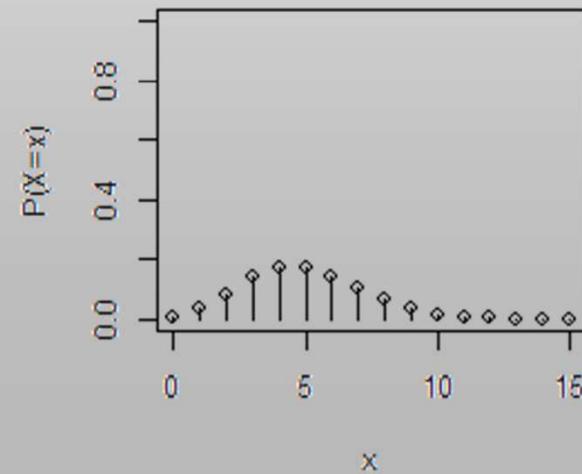
Poisson(1)



Poisson(2)



Poisson(5)





- La distribución Beta es útil cuando lidiamos con proporciones o porcentajes. Veamos un ejemplo:



Promedio de bateo: la proporción entre la cantidad de hits y el número de turnos al bate $[0,1]$, normalmente entre 0,216 y 0,360, con 0,266 como un buen promedio y 0,300 excelente.

- Supongamos: queremos predecir el promedio de un jugador. ¿Podemos usar su promedio de bateo?
- Este problema puede ser representado como una **distribución binomial** (una serie de aciertos y fallos), y la mejor manera de representar estas expectativas previas es con la **distribución beta**



Es decir, antes de ver al jugador lanzar su primer swing, lo que esperamos como su bateo promedio aproximado

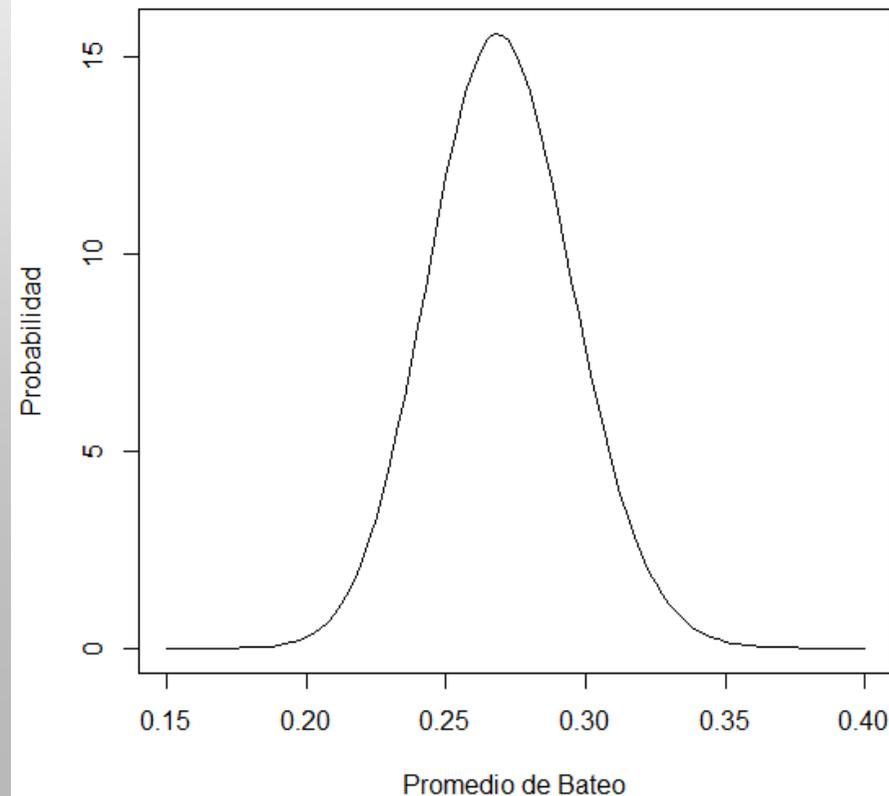
- El dominio de la distribución beta $[0, 1]$, igual que las probabilidades.
- Esperamos que el promedio de bateo del jugador sea aproximadamente 0,27, pero razonablemente está entre 0,21 y 0,35
- Esto puede representarse como una distribución beta con parámetros $\alpha=81$ y $\beta=219$, pues:
 - La esperanza es $\alpha/(\alpha+\beta) = 81/(81+219) = 0.27$
 - Los límites están entre 0,21 y 0,35...

Distribución Beta



```
curve(dbeta(x, 81, 219), xlim= c(0.15,0.4),  
      xlab = "promedio de bateo",  
      ylab = "probabilidad")
```

- La distribución Beta está representando una distribución de *probabilidades*
- Pero ¿Por qué es tan apropiada?





Imaginemos que el jugador batea un único hit. Ahora su registro para la temporada es un hit/un turno al bate.

- Actualizamos nuestras probabilidades y movemos toda la curva un poquito para incluir la nueva información, la nueva distribución beta es:

$$Beta(\alpha_0 + hits, \beta_0 + fallos)$$

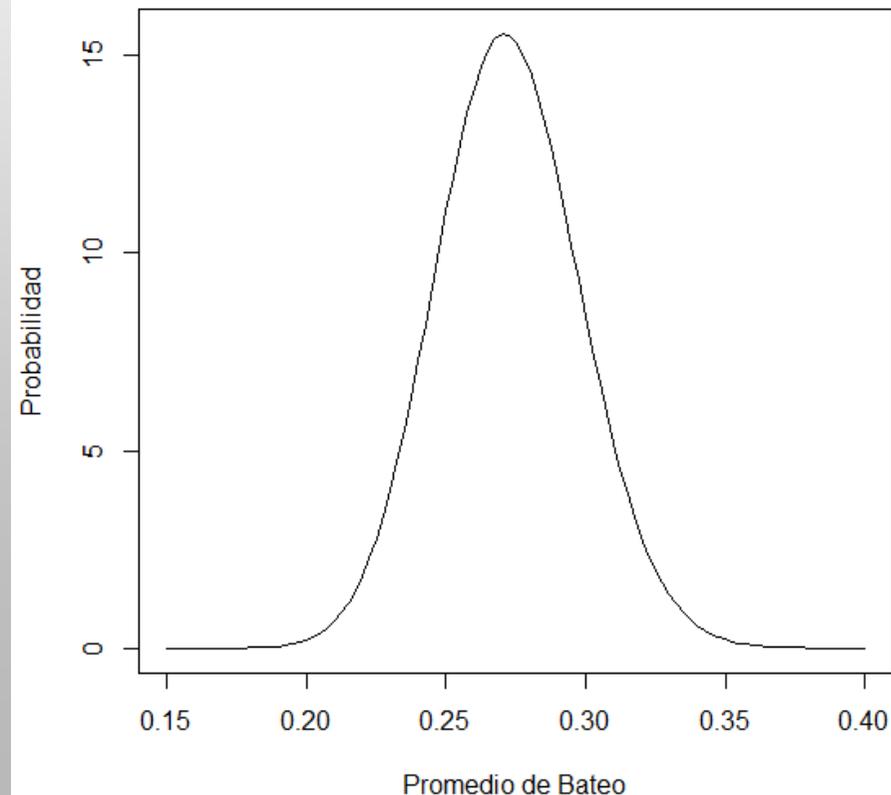
- Donde α_0 y β_0 son los parámetros con los que empezamos (81 y 219)
- En este caso: $beta(81+1, 219)$

Distribución Beta



```
curve(dbeta(x, 82, 219), xlim= c(0.15,0.4),  
      xlab = "promedio de bateo",  
      ylab = "probabilidad")
```

- Vemos que el cambio es imperceptible
- Pero mientras más juegue, la curva se seguirá acomodando a la nueva evidencia, se irá estrechando en la base en la medida que tengamos más evidencia



Distribución Beta

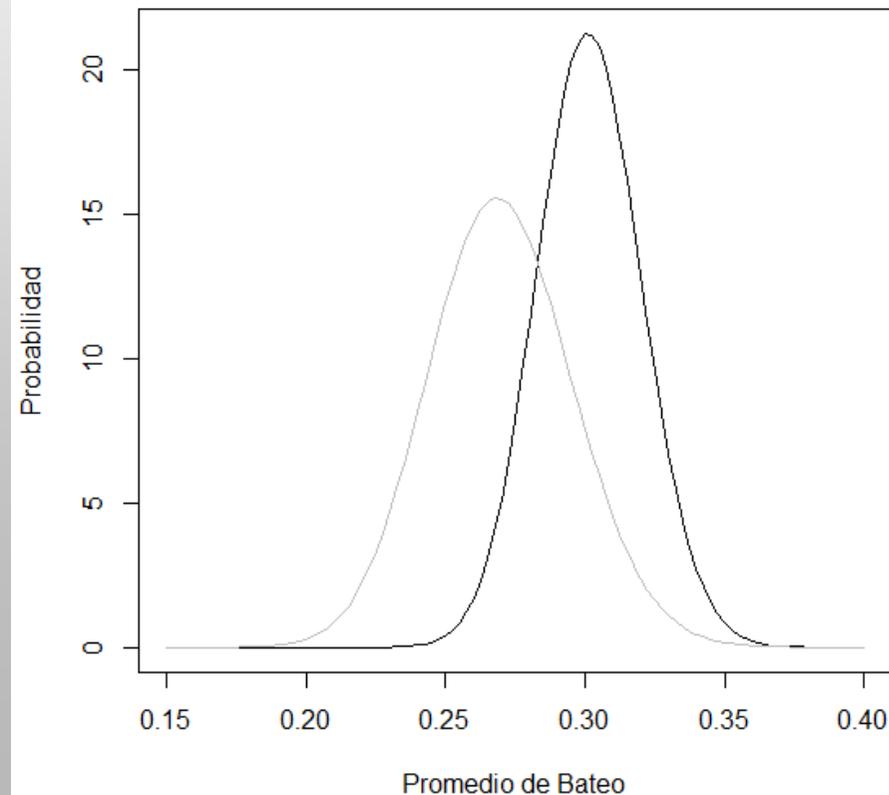


```
curve(dbeta(x, 181, 419), xlim= c(0.15,0.4),  
      xlab = "promedio de bateo",  
      ylab = "probabilidad")
```



Supongamos que a lo largo de la temporada él tuvo 300 turnos al bate y tuvo 100 hits.

- La nueva distribución Beta será...





- Una de las salidas más interesantes de esta formula es la esperanza de la distribución Beta resultante, la cuál es el nuevo estimado.
- Recordemos que la esperanza de la distribución Beta es $\alpha/\alpha+\beta$
- Así, luego de 100 hits en 300 turnos al bate, la esperanza es $181/181+419 = 0.303$
- Note que es mayor que el estimado inicial de = 0.270).

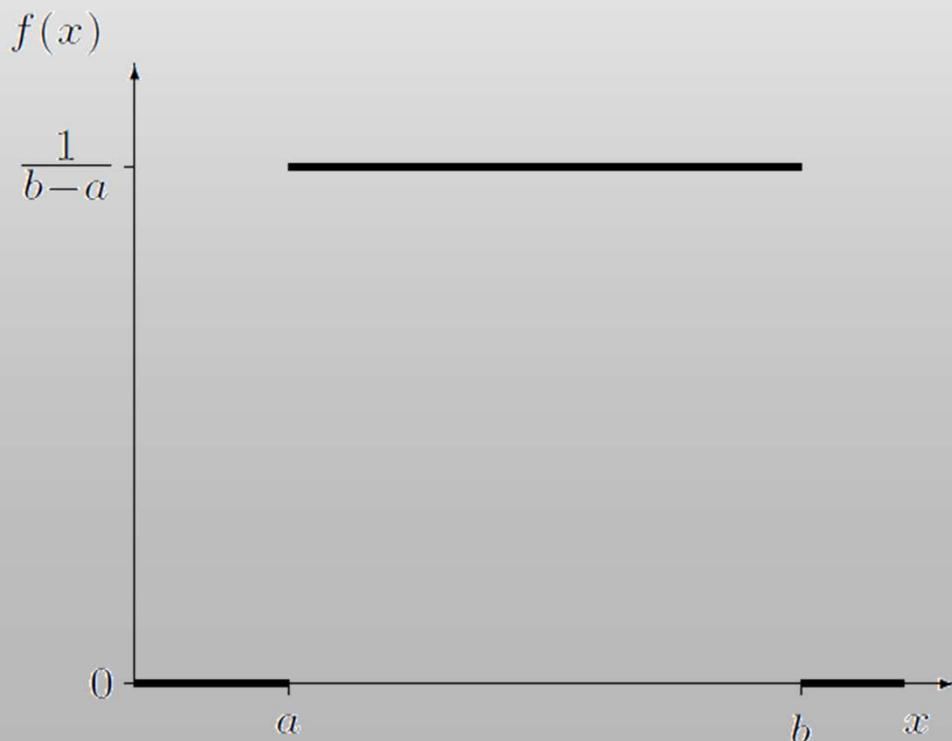


- La distribución uniforme se usa como un primer modelo para una cantidad que varia aleatoriamente entre a y b pero de la cual no se conoce nada más.
- Además, es esencial en la simulación de todas las otras variables aleatorias



- Cuando la p que X se encuentre en un subintervalo dado $[a,b]$ depende sólo de la longitud del intervalo y no de su localización.

$$X \sim \text{unif}(a, b)$$



$$\mu = \frac{a+b}{2}$$
$$\sigma^2 = \frac{(b-a)^2}{12}$$



```
>x <- runif(10^7, 1,2)
```

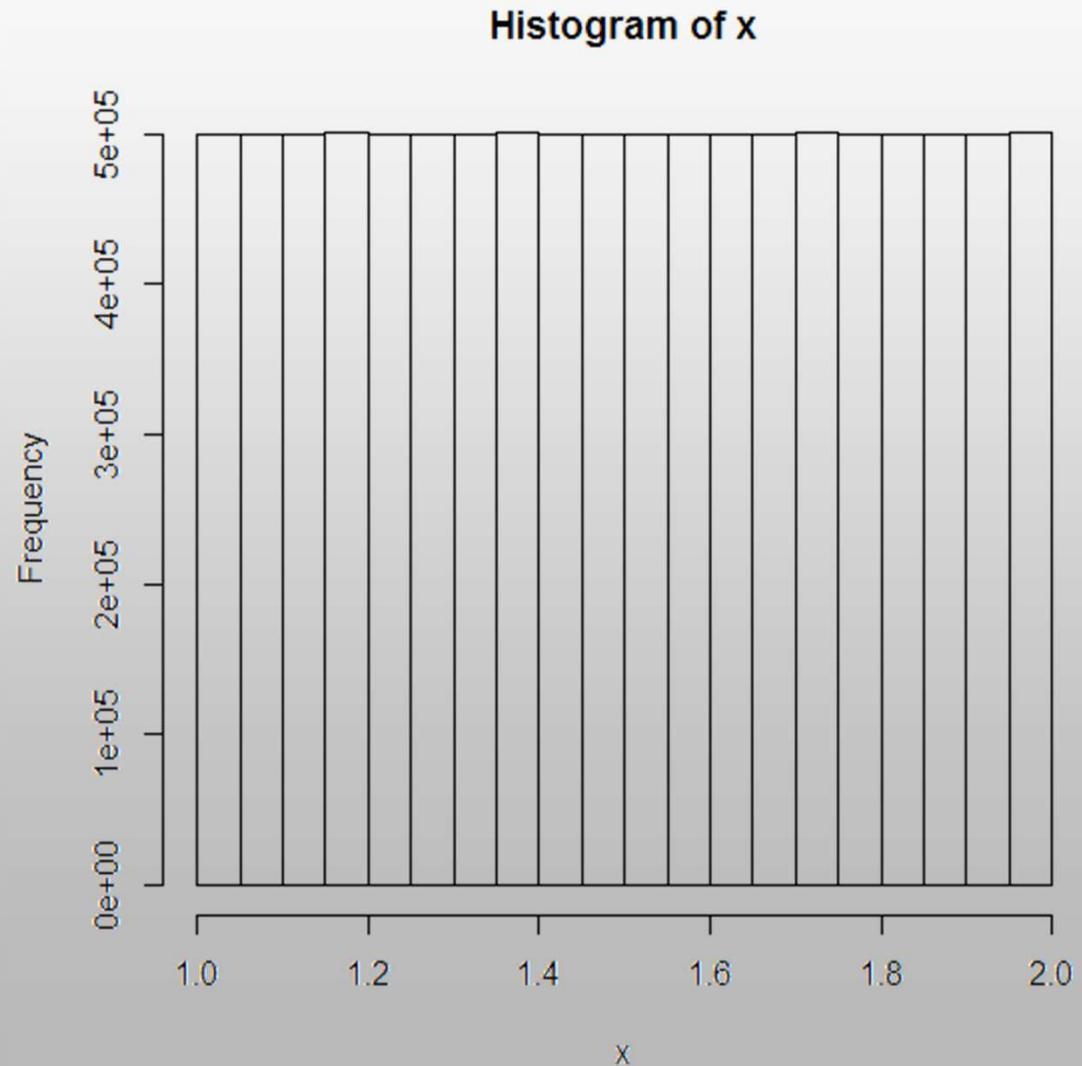
```
>hist(x)
```

```
>mean(x)
```

```
[1] 1.500005
```

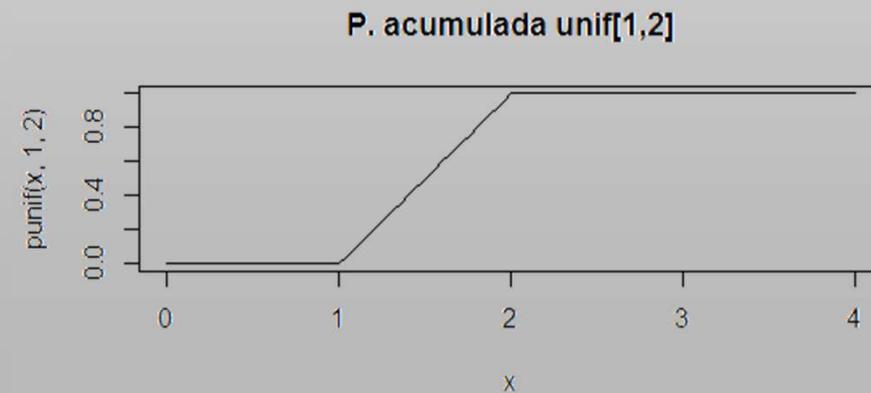
```
>var(x)
```

```
[1] 0.08335182
```





```
> par(mfrow=c(2,1))
> curve(dunif(x,1,2),
       from=0,to=4,
       main="F. de densidad unif[1,2]")
> curve(punif(x,1,2),
       from=0,to=4,
       main="P. acumulada unif[1,2]")
```





- Ejemplo 1:

$X \sim \text{unif}[1,2]$, ¿ $P(X \leq 1.5)$?

$$P(X \leq 1.5) = \int_1^{1.5} dx = 0.5$$

```
> punif(1.5, 1, 2)
```

```
[1] 0.5
```

- ¿Si preguntamos al revés? Es decir, ¿cuál es el valor de z tal que $P(X \leq z)$ sea 0,5 ?

```
> qunif(0.5, 1, 2)
```

```
[1] 1.5
```



- Ejemplo 2:

¿Cuál es la p que gane en la siguiente rueda de la fortuna?

$$X \sim \text{unif}[0, 360^\circ]$$



$$P(X \leq 90^\circ) = \frac{90 - 0}{360 - 0} = \frac{1}{4}$$

```
>punif(0, 90, 360)
```

```
[1] 0.25
```

```
>qunif(0.25, 0, 360)
```

```
[1] 90
```



- Ya hablamos de la distribución $X \sim pois(\lambda)$ como modelo para el n de sucesos raros por unidad de tiempo
- Ahora, queremos estudiar la distribución del tiempo Y entre un suceso y el siguiente
- Así, la distribución de Y es una distribución exponencial con parámetro λ si

$$f(x) = \lambda e^{-\lambda x} \quad \text{para } x \geq 0$$

$$\mu = \frac{1}{\lambda} \quad \sigma^2 = \frac{1}{\lambda^2}$$

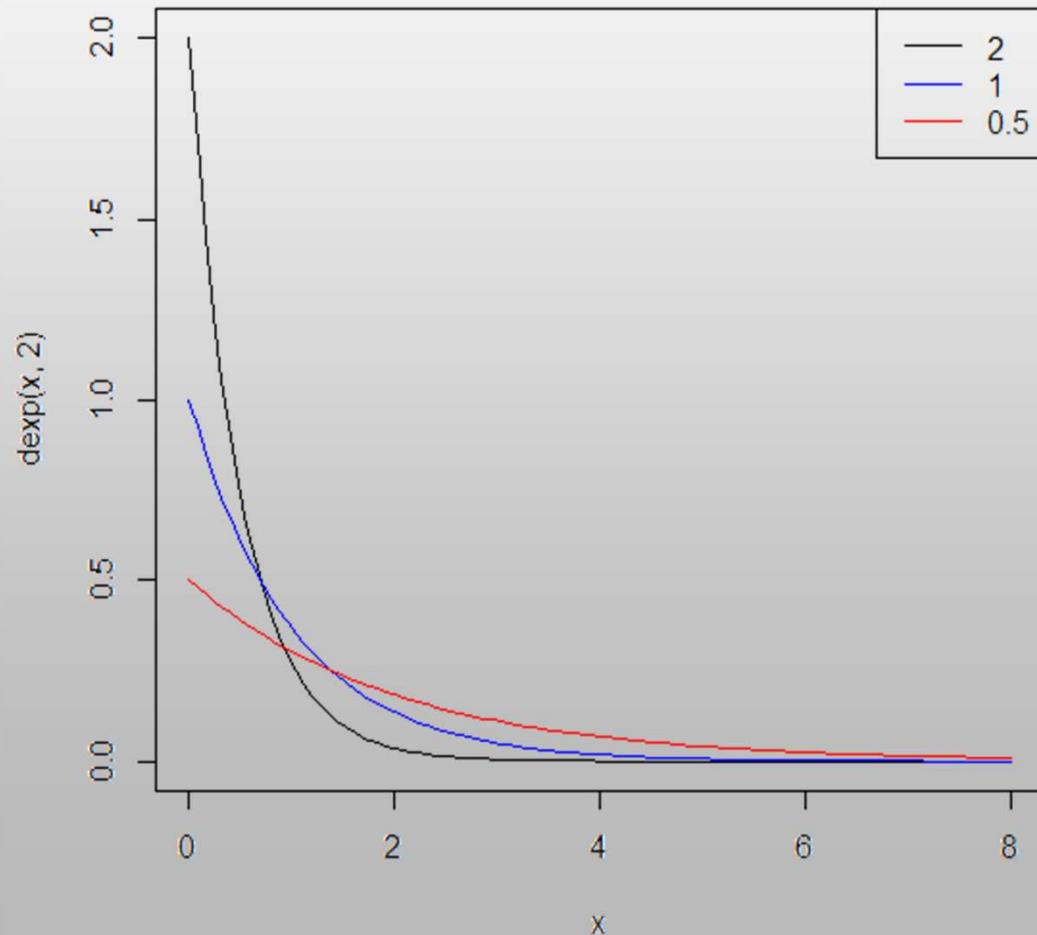


- La distribución $X \sim \text{exp}(\lambda)$ permite modelar duración de elementos:
 - Tiempos de vida
 - Duración de huelgas
 - Periodo de desempleo
 - Tiempo entre llegadas de “clientes” a un sistema que ocurre a una tasa constante
 - Tiempo en el que falla una determinada pieza de un equipo (cuando el efecto del envejecimiento no importa y la falla se produce al azar), etc.

Distribución exponencial



```
> curve(dexp(x,2),from=0, to=8)
> curve(dexp(x,1),from=0, to=8,add=T,col="blue")
> curve(dexp(x,0.5),from=0, to=8, add=T, col="red")
> legend("topright",c("2","1","0.5"),lwd=1,col=c("black","blue","red"))
```





- Ejemplo 1: Supongamos que, en promedio, hay 10 incendios serios al año en Mérida
- Suponemos que el número de incendios por año tiene una distribución $pois(10)$

a) ¿Cuál es el tiempo promedio entre incendios?

$$E[X] = 1/10 \text{ de año} = 365/10 = 36.5 \text{ días}$$



b) Hallar p que después del último incendio, pasen más de dos semanas hasta el siguiente

$$\begin{aligned} P(T > 14) &= \int_{14}^{\infty} \frac{10}{365} e^{-\frac{10}{365}t} dt \\ &= e^{-\frac{10}{365} * 14} \\ &\approx 0.681 \end{aligned}$$

```
>pexp(10/365,14,lower.tail=F)
```

```
[1] 0.6814301
```



- Ejemplo 2, la magnitud de los terremotos en una región puede representarse como una exponencial $\lambda = 0.42$ en escala de Richter. Calcule la probabilidad de que un terremoto que azote la región:

- a) Rebase los 3 grados en la escala de Richter:

$$P(X \geq 3) = \int_x^{\infty} \lambda e^{-\lambda x} dx = e^{-0.42*3} = 0.2865$$

```
>pexp(0.42, 3, lower.tail=F)
```

```
[1] 0.283654
```

- b) Esté entre los 2 y 3 grados en la escala de Richter:

$$P(2 \leq X \leq 3) = P(X \leq 3) - P(X \leq 2)$$

```
>pexp(0.42, 3) - pexp(0.42, 2)
```

```
[1] 0.1480565
```



- Ejemplo 3, el tiempo entre llegadas sucesivas de carros a un punto en la carretera se distribuye como una exponencial con $\lambda = 0.01$ segundos.

a) Hallar la media y varianza de T

$$E[T] = 1/0.01 = 100 \text{ y } V[T] = 1/0,01^2 = 10000$$

b) Una persona empieza a cruzar la calle inmediatamente después que pasa un carro. Si tarda 50 segundos en cruzar la calle, ¿Cuál es la p que lo atropelle el siguiente carro que pasa?

```
> pexp(0.01, 50, lower.tail = F)
```

```
[1] 0.3934693
```



c) ¿Cuál es la p que no pase ningún carro en un minuto?

Sea X el número de carros que llegan en un minuto. La distribución de X es Poisson:

$$X \sim \text{Poisson}(60 \times 0,01) = \text{Poisson}(0,6)$$

$$P(X = 0) = \frac{0.6^0 e^{-0.6}}{0!} \approx 0.549$$

```
> ppois(0,0.6)
```

```
[1] 0.5488116
```



- La distribución exponencial se caracteriza por no poseer “memoria”
- La p de observar un evento en cualquier intervalo de tiempo no depende del tiempo que ha pasado hasta ese intervalo.
- Esto es adecuado cuando los eventos aparecen al azar pero no cuando hay deterioro (i.e., desgaste de una pieza, duración de huelgas, período de desempleo, etc.) del sistema involucrado.



- Una generalización es la distribución de Weibull
- Si $X \sim Weib(\lambda, m)$

$$f(x) = \frac{\lambda}{m} \left(\frac{x}{m}\right)^{\lambda-1} e^{-\left(\frac{x}{m}\right)^\lambda} \quad \text{para } x \geq 0$$

$$\mu = m\Gamma\left(1 + \frac{1}{\lambda}\right) \sigma^2 = m^2 \left[\Gamma\left(1 + \frac{2}{\lambda}\right) - \Gamma\left(1 + \frac{1}{\lambda}\right)^2 \right]$$

$$\Gamma(p) = \int_0^\infty x^{p-1} e^{-x} dx \quad \text{para } p > 0$$

$$\Gamma(p) = (p-1)\Gamma(p-1); \Gamma(1) = 1; \Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$$

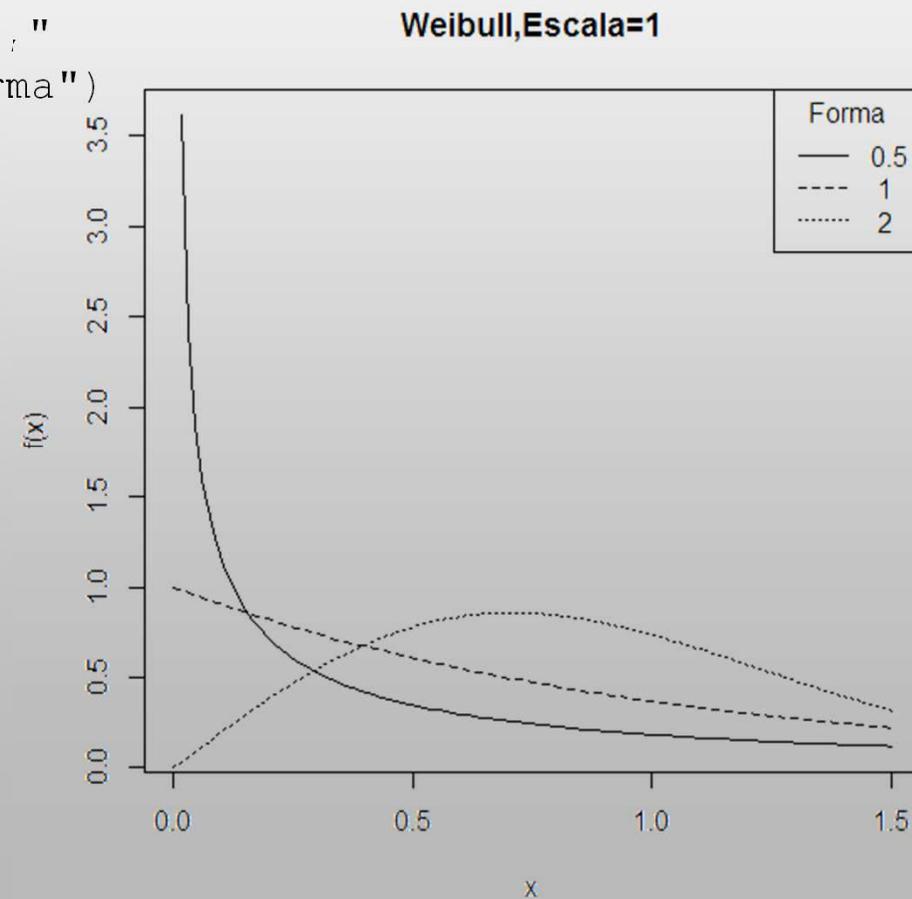
$$\text{Si } n \text{ es entero } \Gamma(n) = (n-1)!$$

Distribución Weibull



```
> curve(dweibull(x,shape=0.5,scale=1),from=0,
        to= 1.5,ylab="f(x)",main="weibull,escala=1")
> curve(dweibull(x,shape=1,scale=1),from=0,
        to= 1.5,lty=2,add=t)
> curve(dweibull(x,shape=2,scale=1),from=0,
        to= 1.5,lty=3,add=t)
> legend("topright",c("0.5"," 1","
  2"),lty=c(1,2,3),title="forma")
```

En R:
shape = λ
scale = m



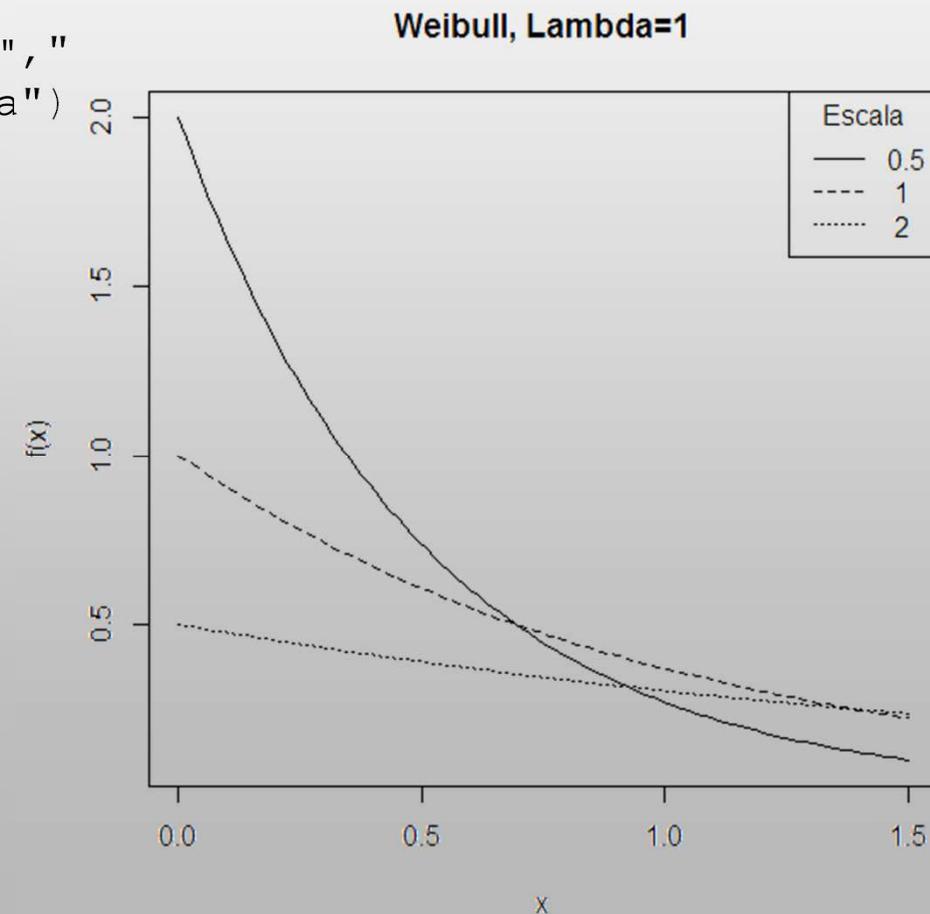
Distribución Weibull



Postgrado en Modelado y Simulación

```
> curve(dweibull(x,shape=1,scale=0.5),from=0,
        to= 1.5,ylab="f(x)",main="Weibull, Lambda=1")
> curve(dweibull(x,shape=1,scale=1),from=0,
        to= 1.5,lty=2,add=T)
> curve(dweibull(x,shape=1,scale=2),from=0,
        to= 1.5,lty=3,add=T)
> legend("topright",c("0.5"," 1","
  2"),lty=c(1,2,3),title="Escala")
```

En R:
shape = λ
scale = m





- En los trabajos pioneros para describir la distribución de la renta, Vilfredo Pareto, tras estudiar la renta en numerosos países, observó que al menos para valores grandes:

$$\ln(N) \approx \ln(A) - \alpha x$$

donde A y $\alpha > 0$ son parámetros y N es el número de individuos que perciben una renta mayor o igual que x



- Sea X una variable aleatoria, la función de Pareto(α, x_0) es

$$f(x) = \begin{cases} 1 - \left(\frac{x_0}{x}\right)^\alpha & \text{si } x \geq x_0 \\ 0 & \text{si } x < x_0 \end{cases}$$

$$E[X] = \frac{\alpha x_0}{\alpha - 1}$$

$$Var[X] = \frac{\alpha x_0^2}{(\alpha - 2)(\alpha - 1)^2}$$



- Si $X \sim \text{gamma}$

$$f(x) = \frac{1}{\Gamma(m)} \lambda^m x^{m-1} e^{-\lambda x} \text{ para } x \geq 0; \lambda, m \geq 0$$

$$\mu = \frac{m}{\lambda} \quad \sigma^2 = \frac{m}{\lambda^2}$$

- En R

>shape (forma) = m

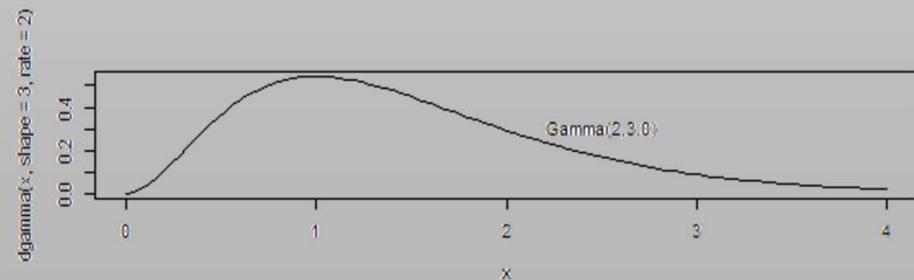
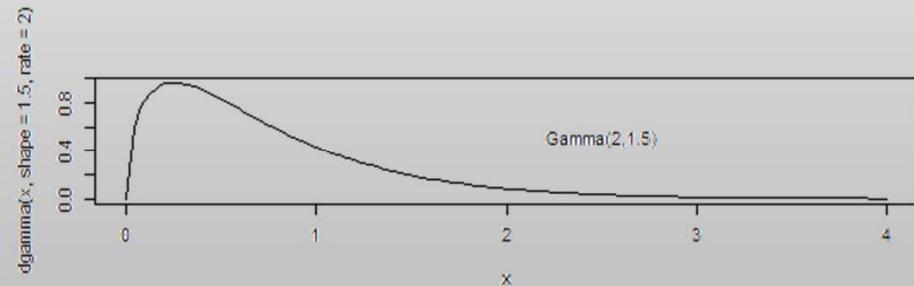
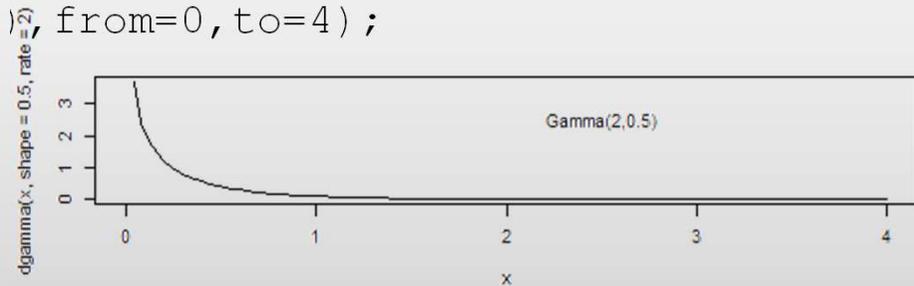
>rate (tasa) = λ

- Si m es entero, se le llama distribución Erlang

Distribución Gamma



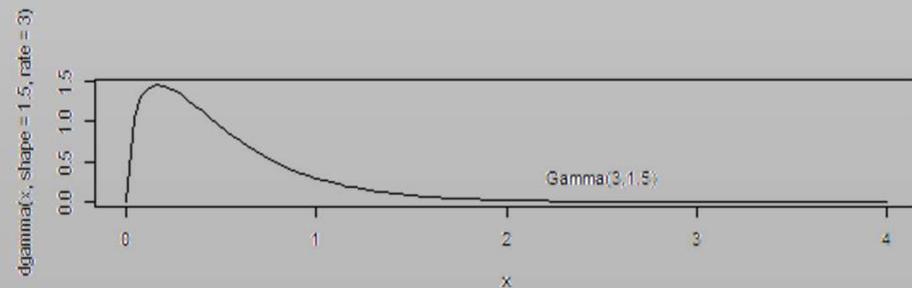
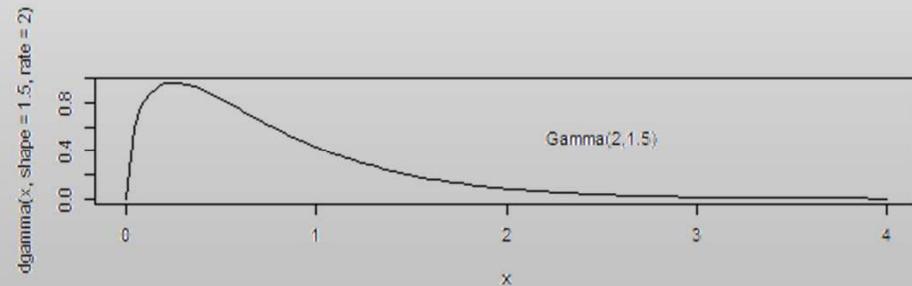
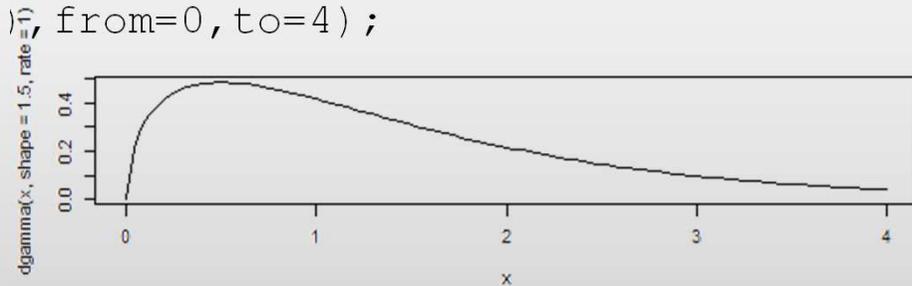
```
> par(mfrow=c(3,1))
> curve(dgamma(x,shape=0.5,rate=2),from=0,to=4);
  text(2.5,2.5,"Gamma(2,0.5)")
> curve(dgamma(x,shape=1.5,rate=2),from=0,to=4);
  text(2.5,0.5,"Gamma(2,1.5)")
> curve(dgamma(x,shape=3.0,rate=2),from=0,to=4);
  text(2.5,0.3,"Gamma(2,3.0)")
```



Distribución Gamma



```
> par(mfrow=c(3,1))
> curve(dgamma(x,shape=1.5,rate=1),from=0,to=4);
  text(2.5,2.5,"Gamma(1,1.5)")
> curve(dgamma(x,shape=1.5,rate=2),from=0,to=4);
  text(2.5,0.5,"Gamma(2,1.5)")
> curve(dgamma(x,shape=1.5,rate=3),from=0,to=4);
  text(2.5,0.3,"Gamma(3,1.5)")
```



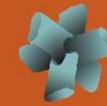


- Las precipitaciones durante un mes de sequía en una cierta región tienen una distribución gamma con parámetros $m=1.6$ y $\lambda=0.5$. Calcule la media y la varianza de esta variable

$$\mu = \frac{m}{\lambda} = 1.6/0.5 = 3.2$$

$$\sigma^2 = \frac{m}{\lambda^2} = 1.6/(0.5^2) = 6.4$$

- ¿Cuál es la probabilidad de que llueva menos que la media?



- Cuando se toma el promedio de un número “suficientemente” grande de una muestra aleatoria iid la distribución del promedio luce como una distribución normal
- También se usa para modelizar errores de medición
- Si $X \sim \text{norm}(\mu, \sigma^2)$ entonces:

$$f(x) = \frac{1}{\sqrt{(2\pi\sigma^2)}} e^{-(x-\mu)^2/(2\sigma^2)} \text{ para } -\infty < x < \infty$$

- $Z \sim \text{norm}(0,1)$ se le conoce como normal estándar. $F(z)$ se denota con la letra ϕ y a $f(z)$ como Φ
- La función de probabilidad acumulada no puede obtenerse analíticamente de allí las famosas tablas de la normal

Distribución normal

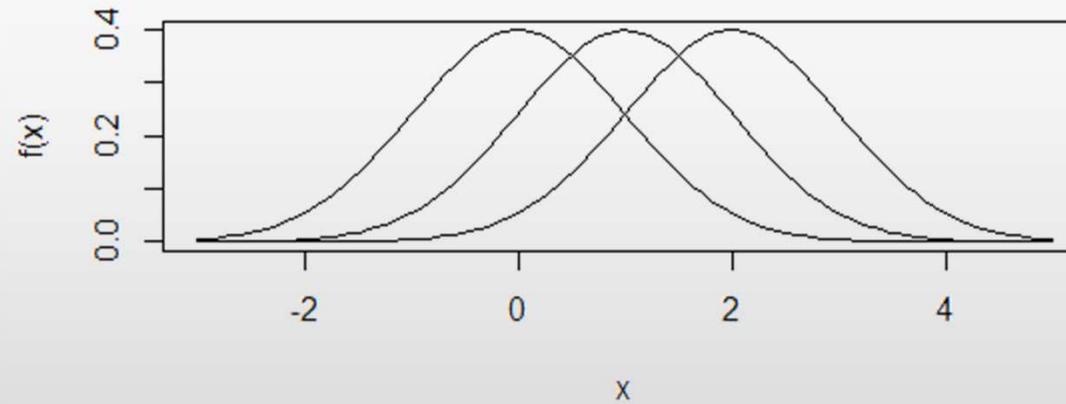


```
> par(mfrow=c(2,1))
> curve(dnorm(x,mean=0,sd=1),from=-3,
  to=5,ylab="f(x)",main="Distribución Normal con
  medias 0,1 y 2 y sigma=1")
> curve(dnorm(x,mean=1,sd=1),from=-3, to=5,add=T);
  curve(dnorm(x,mean=2,sd=1),from=-3, to=5,add=T)
> curve(dnorm(x,mean=0,sd=1),from=-10,
  to=10,ylab="f(x)",main="Distribución Normal con
  media 0 y sigma=1,2 y 3")
> curve(dnorm(x,mean=0,sd=2),from=-10, to=10,add=T);
  curve(dnorm(x,mean=0,sd=3),from=-10, to=10,add=T)
```

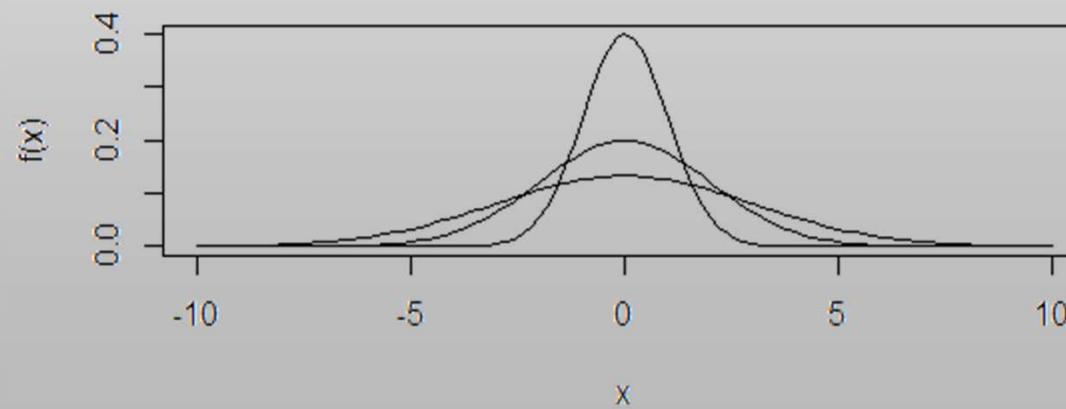
Distribución normal



Distribución Normal con medias 0,1 y 2 y sigma=1



Distribución Normal con media 0 y sigma=1,2 y 3





- Los resultados de un examen de admisión (escala 1-100) poseen una distribución normal con media 75 y desviación 10

a) ¿Qué fracción de los resultados está entre 80 y 90?

$$P(80 < x < 90) = p(x < 90) - p(x < 80)$$

```
> pnorm(90,75,10) - pnorm(80,75,10)
```

```
[1] 0.2417
```

b) ¿Cuál es la probabilidad de obtener una nota superior a 90?

```
> pnorm(90,75,10,lower.tail=F)
```

```
> 1 - pnorm(90,75,10)
```

```
> pnorm(1.5,0,1)          #estandarizando
```

```
[1]0.0668072
```

c) Como el cupo es reducido, ¿Cuál es la nota de corte si quiero que solo ingresen aquellos con notas superiores al 90% de todos los resultados?

```
> qnorm(0.90,75,10)
```

```
[1] 87.81552
```



- La distribución χ^2 : suma de normales estándares al cuadrado. Sirve para pruebas de bondad del ajuste y varianza
- La distribución t de student: similar a la normal pero con colas más anchas. Se usa para calcular IC cuando la varianza es desconocida
- La distribución lognormal: modeliza tiempos de tareas, cantidades que son el producto de un número grande de variables