

# Modelos Matemáticos e Aplicações (15/16)

Módulo I – Revisão dos fundamentos de Probabilidade e Estatística  
com apoio do R

Manuela Neves

ISA/ULisboa

29 Fev 2016

## 1 Variável aleatória – probabilidade

## 2 Principais modelos discretos

- A distribuição uniforme discreta
- A distribuição binomial
- A distribuição binomial negativa
- A distribuição de Poisson

## 3 Alguns Modelos Contínuos

- A distribuição normal ou de Gauss
- O Teorema Limite Central
- A distribuição uniforme contínua
- As distribuições exponencial e gama
- A distribuição beta

## 4 Exemplo de um exercício no

## AULA 2

# Os principais modelos de probabilidade discretos e contínuos.

# O conceito de variável aleatória

Quando se realiza uma experiência aleatória, pode associar-se a cada resultado da experiência um (ou mais) valores reais - diz-se que temos uma **variável aleatória** ou (um **vector aleatório**).

Uma **variável aleatória** costuma representar-se por  **$X$** .

Um variável aleatória pode ser:

- **discreta** - por exemplo o número de sementes germinadas; o registo, a intervalos regulares, do número de pessoas em fila de espera na caixa de um supermercado;
- **contínua** - por exemplo o peso de um indivíduo; a largura, o comprimento de um folha.

# Variável aleatória - probabilidade

Associadas a cada variável aleatória existem:

- uma **função massa de probabilidade**, se  $X$  discreta, ou uma **função densidade**, se  $X$  contínua.
- uma função real  $F$ , a que se chama **função distribuição cumulativa** tal que

$$F(x) = P[X \leq x]$$

Exemplos de cálculo de uma probabilidade:

- 1  $P(a < X \leq b) = P(X \leq b) - P(X \leq a) = F(b) - F(a)$ ;
- 2  $P(X = a) = F(a) - F(a^-)$  onde  $F(a^-) = \lim_{x \rightarrow a^-} F(x)$
- 3  $P(a < X < b) = P(X < b) - P(X \leq a) = F(b^-) - F(a)$ ;

# Principais modelos discretos

## A distribuição uniforme discreta

**Definição** Uma v.a.  $X$  diz-se ter **distribuição uniforme discreta** se toma os valores  $x_1, \dots, x_n$  com probabilidades  $1/n, \dots, 1/n$ , i.e.  
 $P(X = x_i) = 1/n, \quad i = 1, \dots, n.$


### Caso particular

$$X = \begin{cases} 1 & 2 & \dots & n \\ 1/n & 1/n & \dots & 1/n \end{cases}$$

### Valor médio e variância

$$E[X] = \frac{n+1}{2}$$

$$Var[X] = \frac{n^2-1}{12}$$

Instrução no  para simular `> sample(v, size, rep=TRUE)`

$v$  vector com os valores que a variável pode tomar

## A função `sample( )`

A função `sample` - permite criar uma amostra aleatória a partir dos elementos de um vector, **com ou sem reposição**, com probabilidades iguais ou não.

```
>sample(1:20, 15)
```

Selecciona aleatoriamente 15 números de 1 a 20 **sem reposição**  
**a omissão é “sem reposição”**.

Para seleccionar **com reposição** com diferentes probabilidades fazer, por exemplo:

```
>pb<-c(rep(0.1,3), .2, .3, .2);pb  
>sample(1:6,30,rep=T,prob=pb)
```

Se a probabilidade for a mesma pode omitir-se.

**Nota:** para gerar sempre a mesma sucessão fazer `>set.seed( )`

# A distribuição uniforme discreta no R

```
> par(mfrow=c(2,2))
> x1<-sample(1:6,30,rep=T);x1
> dist1<-table(x1);dist1
> plot(dist1)
```





Repetir para 300, 3000 e 30000. (ver variáveis  $x_2$ ,  $x_3$  e  $x_4$  nos gráficos do *slide* seguinte.

**Nota:** Podia definir-se uma função, por exemplo:

```
> dado<-function(n) sample(1:6,n,replace=T)
> d1<-dado(30);table(d1)
> table(dado(30)) # Haverá alguma diferença?
> dado(300);dado(3000)
```



# Gráficos de vários lançamentos



# A distribuição binomial


Quando se realizam  $n$  provas de Bernoulli **independentes**, a variável que conta o número de sucessos que ocorrem diz-se ter **distribuição binomial** e representa-se por  $X \sim \text{Binom}(n, p)$ , sendo  $p$  a probabilidade de sucesso. A probabilidade de insucesso,  $1 - p$ , é costume representar por  $q$ .

$X$  toma os valores  $x = 0, 1, 2, \dots, n$  com probabilidades

$$P[X = x] = \binom{n}{x} p^x (1 - p)^{n-x}$$

## Valor médio e variância

$$E[X] = np \qquad \text{Var}[X] = np(1 - p) = npq$$

Para determinar o valor daquelas probabilidades, quantis ou a função distribuição cumulativa o  possui **funções já definidas** para os modelos implementados.

# Funções no R para os modelos existentes

- **d**função ( $x, \dots$ ) - permite obter a função massa de probabilidade (modelo discreto) ou a função densidade (modelo contínuo) em  $x$ ;
- **p**função( $q, \dots$ ) - permite obter a função de distribuição cumulativa, i.e., devolve a probabilidade de a variável ser menor ou igual a  $q$ ;
- **q**função ( $p, \dots$ ) - permite calcular o quantil associado à probabilidade  $p$ ;
- **r**função ( $n, \dots$ ) - permite gerar uma amostra de  $n$  números pseudo-aleatórios do modelo especificado.

Significado:

**d**ensity, **p**robability, **q**uantile, **r**andom

# Exercícios

**Exercício** Vamos experimentar a utilização das funções `d`, `p`, `q`, `r`. Considere-se uma *Binomial* ( $n = 10, p = 0.2$ ).

```
> x<- 0:10
> dbinom(x,size=10,prob=0.2)
> pbinom(3,size=10,prob=0.2,lower.tail = TRUE) #dá P[X<=3]
> qbinom(0.75, size=10, prob=0.2, lower.tail = TRUE)
+       #dá o quantil de probabilidade 0.75
> rbinom(5, size=10, prob=0.2)
> pbinom(3, size=10, prob=0.2, lower.tail = F) #dá P[X>3]
```

O **quantil** é definido como o **menor valor**  $\chi_p$  tal que  $F(\chi_p) \geq p$ , sendo  $F$  a função distribuição cumulativa.

```
> par(mfrow=c(1,2))
> plot(x,dbinom(x,size=10,prob=0.2),type="h")
> plot(x,dbinom(x,size=10,prob=0.4),type="h")
```

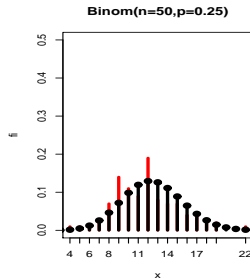




## Exercícios (continuação)

Para exemplificar a **distribuição binomial teórica** e a **simulada** (geração de números pseudo-aleatórios)

```
> par(mfrow=c(1,3))
> n<-5;p<-0.25
> x<-rbinom(100,n,p) # 100 random numbers
> ni<-table(x);ni
> fi<-ni/sum(ni);fi
> dbinom(0:n,size=5,prob=0.25)
> plot(fi,type = "h", col = "red",lwd=3,
+      main="Binom(n=5,p=0.25)",ylim=c(0,.5))
> xvals<-0:n;points(xvals,dbinom(xvals,n,p),type="h",lwd=3)
> points(xvals,dbinom(xvals,n,p),type="p",lwd=3)
```

... Repetir com  $n=15$ ,  $n=50$ .

# Exemplos (continuação)



# Mais modelos de probabilidade

No  $\mathbb{R}$  o modelo Binomial Negativo surge associado a contagens do número de insucessos que se observam até obter  $k$  "sucessos", num contexto de provas de Bernoulli independentes.

A variável  $X$ , nº de contagens nas condições acima referidas diz-se ter **distribuição Binomial Negativa** e é costume representar-se por  $X \sim BN(k, p)$

$p$  é a probabilidade constante de "sucesso" de prova para prova  
 $k$  é o número de "sucessos" que se pretende obter.

# A distribuição binomial negativa

**Caracterização da v.a.  $X \sim BN(k, p)$ :**

Valores  $x = 0, 1, 2, \dots$

Probabilidades  $P[X = x] = \binom{x+k-1}{x} p^k q^x$

$0 < p < 1, \quad q = 1 - p$

**Valor médio e variância de  $X \sim BN(k, p)$**

$$E[X] = \frac{kq}{p}$$

$$\text{Var}[X] = \frac{kq}{p^2}$$

**Exemplo em **


```
> x <- 0:15 #vector de valores da variável
> dnbinom(x,size=6, prob= 0.4) #probabilidade de se
+ # verificarem 0 a 15 insucessos até haver 6 sucessos
+ #outra parametrização que usa o valor médio indicado acima
> dnbinom(x, mu = 9, size = 6)
```



# A distribuição Geométrica

Se  $k = 1$ , isto é, se pretendemos determinar o número de insucessos (falhas) até obter o 1º sucesso, a variável  $X$  diz-se ter **distribuição Geométrica**,  $X \sim \text{Geo}(p)$

```
> Ni <- rgeom(20, prob = 1/4)
> g1 <- table(factor(Ni, 0:max(Ni)))
> plot(g1)
```



# A distribuição de Poisson

**Definição** A v.a  $X$  que conta o número de sucessos que ocorrem num dado intervalo de tempo ou domínio (independentemente do número que ocorre em qualquer outro intervalo ou domínio disjunto) diz-se ter **distribuição de Poisson**.

Depende apenas do parâmetro  $\lambda \rightarrow$  **número médio de sucessos** que ocorrem no intervalo de tempo ( ou na região especificada).

Representa-se por  $X \sim P(\lambda)$  e a lei de probabilidade é:

$$P[X = x] = \frac{e^{-\lambda} \lambda^x}{x!}, \quad x = 0, 1, 2, \dots$$

## Valor médio e variância

$$E[X] = \lambda \quad \text{Var}[X] = \lambda.$$

```
> diff(ppois(c(47, 50), lambda = 50)) # P[47 < X <=50]
> ppois(50,50)-ppois(47,50) # verificar que é o mesmo
```

## A distribuição normal ou de Gauss

Tem um papel fulcral nas Probabilidades e Estatística, porque:

- muitas variáveis biométricas têm uma distribuição muito próxima da normal;
- por vezes uma variável que não é normal pode ser transformada de um modo simples numa outra com distribuição normal;
- a parte central de muitos modelos não normais é por vezes razoavelmente bem aproximada por uma distribuição normal.

Uma v.a. contínua  $X$  diz-se ter **distribuição normal** com parâmetros  $\mu$  e  $\sigma$  e representa-se por  $X \sim \mathcal{N}(\mu, \sigma)$  se a sua f.d.p. é da forma:

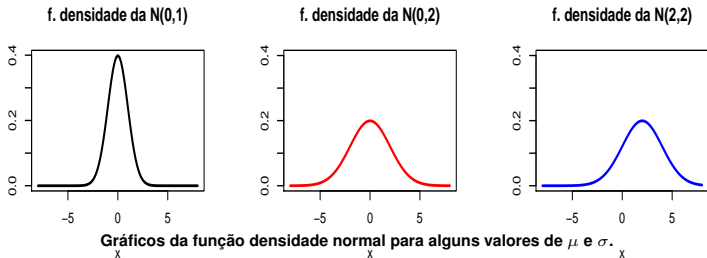
$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right]$$
$$-\infty < x < +\infty, \quad -\infty < \mu < +\infty, \quad 0 < \sigma < +\infty$$

# A distribuição normal ou de Gauss

## Propriedades da curva densidade da distribuição normal

1. É simétrica relativamente a  $\mu$ .
2. É uma curva unimodal, a moda é  $\mu$ .
3. Tem pontos de inflexão em  $\mu + \sigma$  e  $\mu - \sigma$ .

Se  $\mu = 0$  e  $\sigma = 1$  a variável aleatória com distribuição  $\mathcal{N}(0, 1)$  chama-se **normal reduzida** e costuma representar-se por  $Z$ ,  $Z \sim \mathcal{N}(0, 1)$

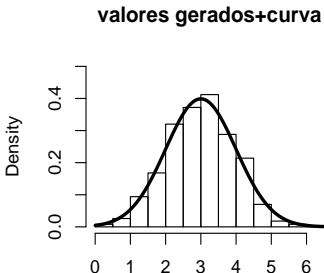



# Exercícios com a distribuição normal no R

```
#cálculos e gráficos com a normal
> pnorm(1.96)
> pnorm(-1.96)
> pnorm(3,mean=5,sd=2)
> qnorm(0.75,mean=5,sd=1)
> qnorm(0.75,mean=5,sd=1,lower.tail=T)
> qnorm(0.25,mean=5,sd=1,lower.tail=F)
+           #graficos
> par(mfrow=c(1,2))
> x<-seq(-7,7,.01)
> plot(x,dnorm(x,0,1),type="l",ylim=c(0,.8),lwd=5)
> lines(x,dnorm(x,0,.6),col="red",lwd=3)
> lines(x,dnorm(x,0,2),col="blue",lwd=3)
> lines(x,dnorm(x,1,.6),col="blue",lwd=3)
```

# A distribuição normal (gráficos)

```
# gerar valores (continuação do exercício)
> y<-rnorm(1000,mean=3,sd=1)
> hist(y,freq=F,ylim=c(0,0.5),
+ main="valores gerados+curva",col=gray(.9))
> curve(dnorm(x,mean=3,sd=1),add=T,lwd=3)
```



# Resultados importantes com a distribuição normal

- Seja  $X \sim \mathcal{N}(\mu, \sigma)$  então a v.a.  $\frac{X - \mu}{\sigma}$  tem distribuição normal reduzida, i.e.,  $Z = \frac{X - \mu}{\sigma} \sim \mathcal{N}(0, 1)$ .
- Sejam  $X_i$   $n$  v.a. normais independentes e semelhantes, i.e., tendo todas o mesmo valor médio  $\mu$  e a mesma variância  $\sigma^2$ .  
As variáveis aleatórias **soma** e **média**, definidas respectivamente como  $S_n = \sum_{i=1}^n X_i$  e  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$  têm distribuição normal assim definida  
 $S_n \sim \mathcal{N}(n\mu, \sigma\sqrt{n})$  e  $\bar{X}_n \sim \mathcal{N}(\mu, \sigma/\sqrt{n})$ .

# O Teorema Limite Central

Vimos que a soma de normais independentes é ainda uma normal. Mas a **distribuição aproximada da soma de  $n$  variáveis aleatórias independentes e identicamente distribuídas**, sob certas condições é também **normal**.

## O Teorema limite central

Sejam  $X_1, \dots, X_n$  variáveis aleatórias independentes e identicamente distribuídas, com valor médio  $\mu$  e variância  $\sigma^2$  (finita). Se  $n$  'grande' a v.a.  $S_n = \sum_{i=1}^n X_i$ , verifica:

$$\frac{S_n - n\mu}{\sigma\sqrt{n}} \sim \mathcal{N}(0, 1) \quad \text{e também se tem} \quad \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1).$$




# O Teorema Limite Central...exercício


```
> # População Uniforme(0,5)
> par(mfrow=c(2,2))
> am<-500
> vec.med<-c(rep(0,am))
> n<-c(2,3,10,30)
> for(j in 1:4)
+ {for(i in 1:am)
+ {x<-runif(n[j],0,5)
+ vec.med[i]<-mean(x)}
+ qqnorm(vec.med,main=paste("Q-QPlot Normal, n =",n[j],
+ "n","Médias Pop. U(0,5),"),xlab=" ",
+ col="red")
+ qqline(vec.med,col="darkred")}
```

# O Teorema Limite Central...exercício


Q-QPlot Normal,  $n = 2$   
Médias Pop.  $U(0,5)$ ,




Q-QPlot Normal,  $n = 3$   
Médias Pop.  $U(0,5)$ ,



Q-QPlot Normal,  $n = 10$   
Médias Pop.  $U(0,5)$ ,



Q-QPlot Normal,  $n = 30$   
Médias Pop.  $U(0,5)$ ,



# Aplicações do Teorema Limite Central

Seja  $X$  uma v.a. com distribuição binomial com valor médio  $\mu = np$  e variância  $\sigma^2 = npq$ .

$X \sim \mathcal{B}(n, p)$ , i.e., valor médio  $\mu = np$  e variância  $\sigma^2 = npq$

$$\frac{X - np}{\sqrt{npq}} \sim \mathcal{N}(0, 1) \quad \text{se} \quad n \rightarrow \infty$$

**Regra prática** Se na distribuição binomial,  $np > 5$  e  $nq > 5 \implies$  a aproximação pela distribuição normal é boa.

$$X \sim P(\lambda)$$

Se  $\lambda \rightarrow \infty$  então  $\frac{X - \lambda}{\sqrt{\lambda}} \sim \mathcal{N}(0, 1)$ .

## Mais uma convergência

Se na distribuição binomial  $n \rightarrow \infty$  e  $p$  pequeno (digamos  $p < 0.05$  e  $n > 20$ )  $X \sim B(n, p) \sim P(np)$



# Outras distribuições contínuas

## Distribuição uniforme contínua e exponencial

```
> u<-runif(100)
> hist(u,freq=F,col=gray(.9),main="uniforme")
> curve(dunif(x),add=T,lwd=3)
```

### ... e Exponencial de valor médio 2500

```
> x<-rexp(100,1/2500)
> hist(x,probability=TRUE,col=gray(.9),main="Exponencial
+ com média 2500")
> curve(dexp(x,1/2500),add=T)
```



# A distribuição gama

Em muitas áreas das ciências há ainda muitas situações em que a lei de Gauss não serve para modelar o fenómeno.

Começemos por referir brevemente a **distribuição gama** que deve o seu nome à **função gama**, estudada em muitas áreas da matemática, assim definida:

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

**Algumas propriedades** da função gama:

- $\Gamma(\alpha) = (\alpha - 1)\Gamma(\alpha - 1)$  (fórmula de recorrência)
- No caso de  $\alpha = n$  inteiro, é fácil verificar que se tem

$$\Gamma(n) = (n - 1)(n - 2)\dots\Gamma(1) = (n - 1)!$$

# A distribuição gama

**Mais algumas propriedades** da função gama:

- $\Gamma(1/2) = \sqrt{\pi}$
- As derivadas da função gama são assim definidas:

$$\Gamma^{(k)}(\alpha) = \int_0^{\infty} x^{\alpha-1} (\log x)^k e^{-x} dx$$

Alguns valores particulares das derivadas úteis em muitas aplicações são

$\Gamma'(1) = \gamma = 0.57722\dots$  valor é designado por **constante de Euler**


$\Gamma''(1) = \gamma^2 + \pi^2/6 = 1.97811\dots$

# A distribuição gama


Uma v.a. diz-se ter **distribuição gama** de parâmetros  $\alpha$  e  $\beta$ , ( $\alpha > 0$ ,  $\beta > 0$ ) e escreve-se  $X \sim G(\alpha, \beta)$  se ( $\alpha$  – parâmetro de forma e  $\beta$  – parâmetro de escala) função densidade é:

$$f(x) = \begin{cases} \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta} & x > 0 \\ 0 & x \leq 0 \end{cases}$$


f. dens. da Gamma(0.5,1)



f. dens. da Gamma(2,2)



f. dens. da Gamma(6,2)



Gráficos da função densidade de uma v.a. com distribuição  $G(1/2, 1)$ ,  $G(2, 2)$  e  $G(6, 2)$ , da esquerda para a direita, respectivamente.



# A distribuição gama

Valor médio e variância de  $X \sim G(\alpha, \beta)$

$$E[X] = \alpha \beta \quad \text{Var}[X] = \alpha \beta^2$$

Um caso particular muito importante é o que se obtém fazendo  $\alpha = 1$ . A v.a. resultante diz-se ter **distribuição exponencial**, foi falada atrás, representa-se por  $X \sim \text{Exp}(\beta)$  e a função densidade é assim definida,

$$f(x) = \begin{cases} \frac{1}{\beta} e^{-x/\beta} & x > 0 \quad \beta > 0 \\ 0 & x \leq 0 \end{cases}$$

# A distribuição exponencial

## Valor médio e variância

$$E[X] = \beta$$

$$\text{Var}[X] = \beta^2$$

A distribuição exponencial tem sido **largamente usada como um modelo de problemas relativos a duração de vida, teoria da fiabilidade, tempos de espera**, etc.

## Propriedade

Se  $X_i, i = 1, \dots, n$  são variáveis aleatórias independentes e semelhantes, com distribuição  $\text{Exp}(\beta)$ , então

$$\sum_{i=1}^n X_i \sim G(n, \beta).$$

# A distribuição exponencial

## Observações:

- Existe uma relação muito importante entre a distribuição exponencial e a distribuição de Poisson, que surge muitas vezes na prática. Estando a observar a **ocorrência de certos acontecimentos em intervalos de tempo**, pretendemos caracterizar  $T$  o tempo ao fim do qual se verifica a primeira ocorrência.

## Teorema

Seja  $X$  uma v.a. de Poisson de parâmetro  $\lambda$ . Seja  $T$  a v.a. que designa o tempo de espera pela ocorrência do primeiro acontecimento, então  $T$  tem distribuição exponencial,  $T \sim \text{Exp}[\beta]$ , de parâmetro  $\beta = 1/\lambda$ .

# A distribuição beta

Uma v.a.  $X$  contínua diz-se ter **distribuição beta** de parâmetros  $(m, n)$  e escreve-se  $X \sim Be(m, n)$  se a sua função densidade é da forma

$$f(x) = \begin{cases} \frac{1}{B(m,n)} x^{m-1} (1-x)^{n-1} & 0 < x < 1 \quad m > 0, n > 0 \\ 0 & \text{outros valores de } x \end{cases}$$

onde  $B(m, n)$  é a **função beta** assim definida

$$B(m, n) = \frac{\Gamma(m)\Gamma(n)}{\Gamma(m+n)} = \int_0^1 x^{m-1} (1-x)^{n-1} dx$$

# A distribuição beta

## Propriedades

1.  $B(m, n) = B(n, m)$

2.  $B(1, 1) = 1$

3.  $B\left(\frac{1}{2}, \frac{1}{2}\right) = \pi$

4.  $B(m, n) = \int_0^{+\infty} \frac{x^{m-1}}{(1+x)^{m+n}} dx$

## Valor médio e variância da distribuição beta

$$E[X] = \frac{m}{m+n}$$

$$\text{var}[X] = \frac{mn}{(m+n)^2(m+n+1)}$$

# A distribuição beta









A função densidade da v.a. com distribuição beta apresenta, como dissemos, uma grande variabilidade de formas.

Assim podemos caracterizar o aspecto da densidade em função do valor dos parâmetros.

- se  $m > 1, n > 1 \Rightarrow$  existe uma única moda em  $x = (m - 1)/(m + n - 2)$
- se  $m < 1, n < 1 \Rightarrow$  existe uma antimoda (forma de U)
- se  $(m - 1)(n - 1) \leq 0 \Rightarrow$  forma de J
- se  $m = n \Rightarrow$  simetria relativamente a 0.5.

# A distribuição beta

Nas figuras seguintes, vejam-se alguns desses aspectos:



# A distribuição beta

Sejam  $X$  e  $Y$  variáveis aleatórias independentes tais que  $X \sim G(a_1, b_1)$  e  $Y \sim G(a_2, b_2)$ , então


$$X|(X + Y) \sim Be(a_1, a_2).$$

A distribuição beta, acabada de estudar diz-se estar na forma estandardizada e é de facto a forma mais usada. A sua forma mais geral apresenta quatro parâmetros  $(a, b, m, n)$  e a função densidade é

$$f(x) = \begin{cases} \frac{1}{B(m,n)} \frac{(x-a)^{m-1}(b-x)^{n-1}}{(b-a)^{m+n-1}} & a < x < b \quad m > 0, n > 0 \\ 0 & \text{outros valores de } x \end{cases}$$



# RESUMO de algumas distribuições no R




Nome da distribuição no 	Função	Argumentos
Beta	beta	shape1, shape2
Binomial	binom	size, prob
Cauchy	cauchy	location, scale
Chisquare	chisq	df
Exponential	exp	rate
FDist	f	df1, df2
GammaDist	gamma	shape, scale
Geometric	geom	prob
Hypergeometric	hyper	m, n, k
Lognormal	lnorm	meanlog, sdlog
Logistic	logis	location, scale
NegBinomial	nbinom	size, prob
Normal	norm	mean, sd
Poisson	pois	lambda
TDist	t	df
Uniform	unif	min,max
Weibull	weibull	shape, scale

# Exemplo de um exercício no R

Considera-se a seguinte função  $f(x) = \begin{cases} 2 e^{-2x} & x > 0 \\ 0 & x \leq 0 \end{cases}$

Vamos ver que  $f$  é uma função densidade e calcular  $P[X > 1]$  e  $P[0.2 < X < 0.8]$

```
>funcao<-function(x) {  
+   fx<-ifelse(x<0,0,2*exp(-2*x))  
+   return(fx)}  
>par(mfrow=c(1,3))  
>plot(funcao);plot(funcao,0,10);plot(funcao,0,5)
```



# Exemplo de um exercício no R

```
>integrate(funcao,0,Inf)
>integrate(funcao,1,Inf)
>res<-integrate(funcao,0,1);res;str(res)
>1-res$value
```

```
1 with absolute error < 5e-07
0.1353353 with absolute error < 2.1e-05
0.8646647 with absolute error < 9.6e-15
List of 5
 $ value      : num 0.865
 $ abs.error  : num 9.6e-15
 $ subdivisions: int 1
 $ message    : chr "OK"
 $ call       : language integrate(f =funcao,lower = 0,upper = 1)
               attr(*, "class")= chr "integrate"
[1] 0.1353353
```