AULA 2

Breve revisão de conceitos relacionados com variáveis aleatórias e modelos de probabilidade.

Plano da aula 2

1. O conceito de variável aleatória – cálculo de probabilidades
2. Parâmetros de uma variável aleatória
3. Parâmetros em pares aleatórios
4. Principais modelos discretos
   - A distribuição uniforme discreta
   - A distribuição binomial e binomial negativa
   - A distribuição de Poisson
5. Principais modelos contínuos
   - A distribuição normal ou de Gauss
   - O Teorema Limite Central
   - A distribuição uniforme contínua
   - As distribuições exponencial, gama e beta
6. Uma breve introdução à teoria de valores extremos
7. Porquê a Teoria de Valores Extremos?

O conceito de variável aleatória—- cálculo de probabilidades

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 $\boldsymbol{X}$.

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 - cálculo de probabilidade

Associadas a cada variável aleatória existem:

- uma função massa de probabilidade, se X **discreta**.

A função massa de probabilidade é a aplicação que
a cada valor $x_i \longrightarrow p_i = P[X = x_i]$, verificando:
$p_i \geq 0, \ \ i = 1, ..., k$ e $\sum_{i=1}^{k} p_i = 1.$

- ou uma função densidade, se X **contínua**.

Uma função f diz-se **função densidade de probabilidade** ou apenas **função densidade** se verificar as seguintes condições:

$$f(x) \geq 0 \quad \forall x \in \mathbb{R}; \qquad \int_{-\infty}^{+\infty} f(x)\, dx = 1$$

Variável aleatória - cálculo de probabilidade

Associada a cada variável aleatória tem-se também:

- uma função real F, a que se chama função distribuição cumulativa assim definida:

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

Se X discreta tem-se $F(x) = P[X \leq x] = \sum_{x_i \leq x} P[X = x_i]$,
ou seja temos a probabilidade cumulativa associada à variável X calculada em qualquer $x \in \mathbb{R}$.

Se X contínua tem-se $F(x) = P[X \leq x] = \int_{-\infty}^{x} f(t)\, dt$
$-\infty < x < \infty$ sendo f a função densidade.

Variável aleatória - cálculo de probabilidade

Exemplos de cálculo de uma probabilidade com recurso à função distribuição cumulativa:

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 $F(a^-) = lim_{x \to a^-} F(x)$
3. $P(a < X < b) = P(X < b) - P(X \leq a) = F(b^-) - F(a)$;

Parâmetros de uma variável aleatória

Valor médio

Dada uma v.a. X chama-se **valor médio** ou **valor esperado** e representa-se por $E[X]$, μ_X ou simplesmente μ a

$$E[X] = \sum_{i=1}^{n} x_i \, p_i \qquad X \text{ é v.a. discreta com distribuição } (x_i, p_i)$$

$$E[X] = \int_{-\infty}^{+\infty} x \, f(x) \, dx \qquad X \text{ é v.a. contínua com f.d.p. } f(x)$$

Algumas propriedades

- $E[a + bX] = a + b\,E[X]$.
- $E[\varphi(X) + \psi(X)] = E[\varphi(X)] + E[\psi(X)]$
- $inf(X) \leq E[X] \leq sup(X)$

Parâmetros de uma variável aleatória

Variância

Chama-se **variância** de uma variável aleatória X e representa-se por $\boldsymbol{Var[X]}$, σ^2_X ou apenas σ^2 a

$$\sigma^2_X = \boldsymbol{E}\left[(\boldsymbol{X} - \mu)^2\right]$$

$\sigma_X = \sqrt{\boldsymbol{Var[X]}}$ chama-se **desvio padrão**.

Algumas propriedades

- $Var[X] = E[X^2] - (E[X])^2$
- $Var[X] \geq 0$
- $Var[a + b\ X] = b^2\ Var[X]$.

Para o desvio padrão tem-se $\sigma_{(a+b\ X)} = |b|\ \sigma_X$

Parâmetros em pares aleatórios

Breve revisão de propriedades dos parâmetros em pares aleatórios

Se (X, Y) é um par aleatório, podendo ser **discreto** ou **contínuo**

Valor médio

Dado o par aleatório (X, Y), e $g : \mathbb{R}^2 \to \mathbb{R}$, define-se

$$E[g(X, Y)] = \sum_i \sum_j g(x_i, y_j)\, p_{ij} \;, \qquad \text{no caso discreto}$$

$$E[g(X, Y)] = \int \int_{R^2} g(x, y)\, f(x, y)\, dxdy \;, \qquad \text{no caso contínuo.}$$

Propriedades do Valor Médio

- $E[X \pm Y] = E[X] \pm E[Y]$

- **Desigualdade de Schwarz** Se $E[X^2]$ e $E[Y^2]$ existem então $(E[XY])^2 \leq E[X^2]E[Y^2]$.

  Corolário: $(E[X])^2 \leq E[X^2]$
  Nota: se $E[X^2]$ existe $\Longrightarrow$ existe $E[X]$.

- Se X e Y **variáveis aleatórias independentes**

$$\Downarrow$$

$$E[XY] = E[X]E[Y]$$

Nota: O recíproco não é verdadeiro

A covariância e propriedades da variância

Covariância entre X e Y

Dado o par aleatório (X, Y) chama-se **covariância** de X e Y a

$$\boldsymbol{Cov}[\boldsymbol{X}, \boldsymbol{Y}] \equiv \sigma_{\boldsymbol{XY}} = \boldsymbol{E}[(\boldsymbol{X} - \mu_{\boldsymbol{X}})(\boldsymbol{Y} - \mu_{\boldsymbol{Y}})]$$

Exercício

Verifique que $\boldsymbol{Cov}[\boldsymbol{X}, \boldsymbol{Y}] = \boldsymbol{E}[\boldsymbol{XY}] - \boldsymbol{E}[\boldsymbol{X}]\boldsymbol{E}[\boldsymbol{Y}]$

Propriedades da variância e da covariância

- Sejam X e Y variáveis aleatórias.

$$Var[X \pm Y] = Var[X] + Var[Y] \pm 2Cov[X, Y]$$

- Se X e Y são v. a.'s **independentes** $\Longrightarrow Cov[X, Y] = 0$.
  Nota: O recíproco não é verdadeiro.

- Se X e Y são variáveis aleatórias **independentes**

$$Var[X \pm Y] = Var[X] + Var[Y]$$

- $Cov[a + bX, c + dY] = bd\ Cov[X, Y]$.

- $|Cov[X, Y]| \leq \sigma_X\ \sigma_Y$.

- **Coeficiente de correlação** define-se como:

$$\rho \equiv \rho_{X,Y} = \frac{Cov[X, Y]}{\sigma_X\ \sigma_Y} \qquad (\sigma_X > 0; \sigma_Y > 0).$$

Os principais modelos de probabilidade discretos e contínuos.

Principais modelos discretos

A distribuição uniforme discreta

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

Caso particular

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

Valor médio e variância

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

Instrução no R 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

```
> 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

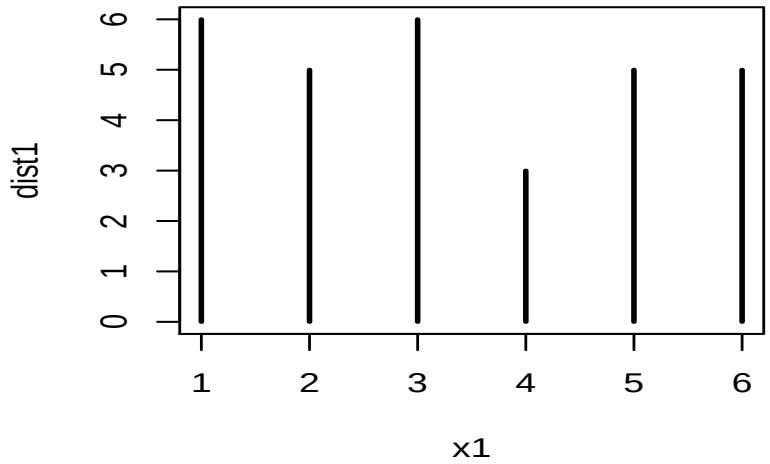

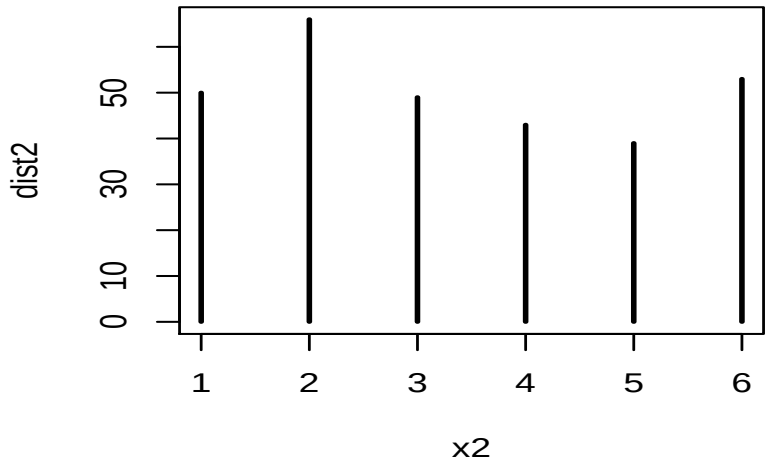

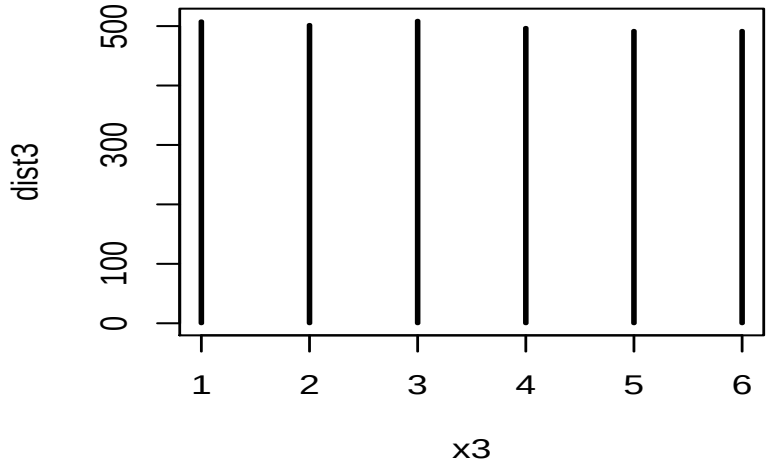

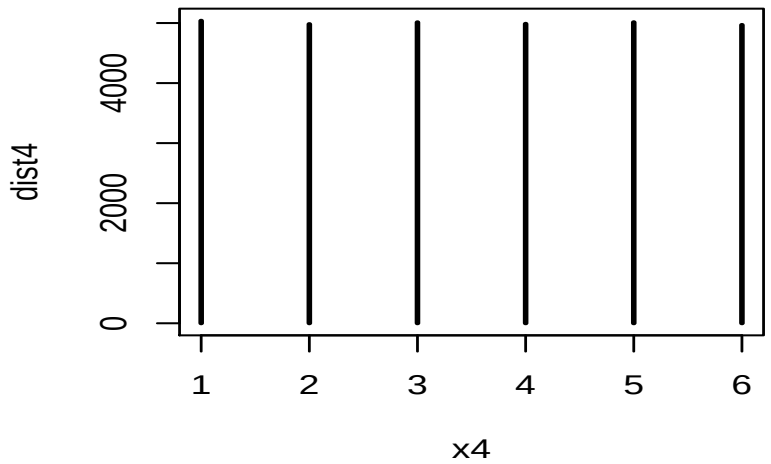

A distribuição binomial

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 $X \frown Binom(n, p)$, sendo p a probabilidade de sucesso. A probabilidade de insucesso, $1 - p$, é costume representar por q.

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

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

Valor médio e variância

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

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

Significado:

`density, probability, quantile, random`

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 χ_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)

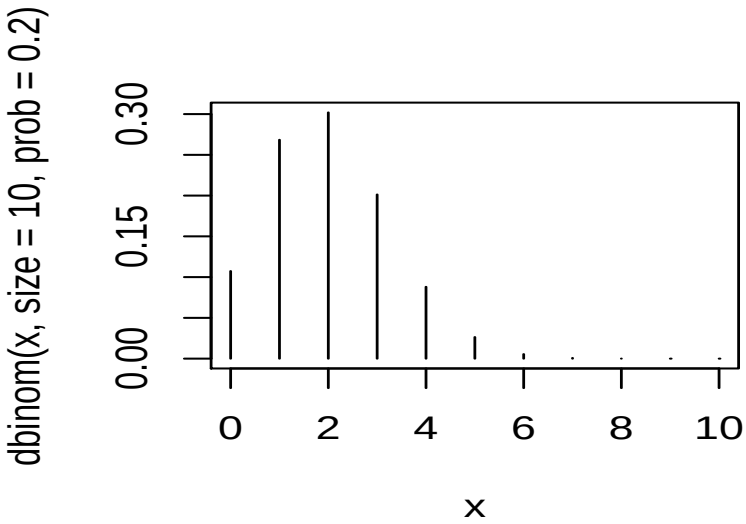

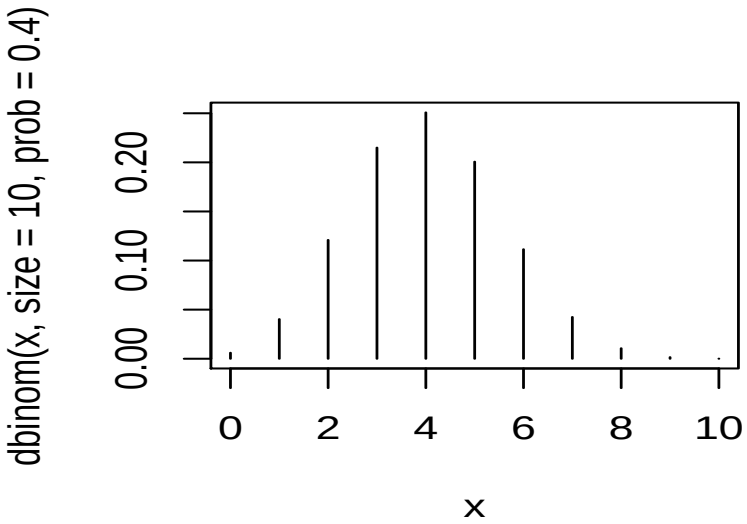

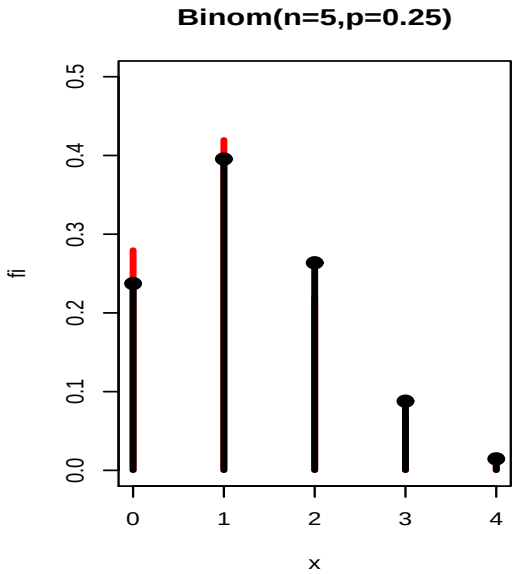

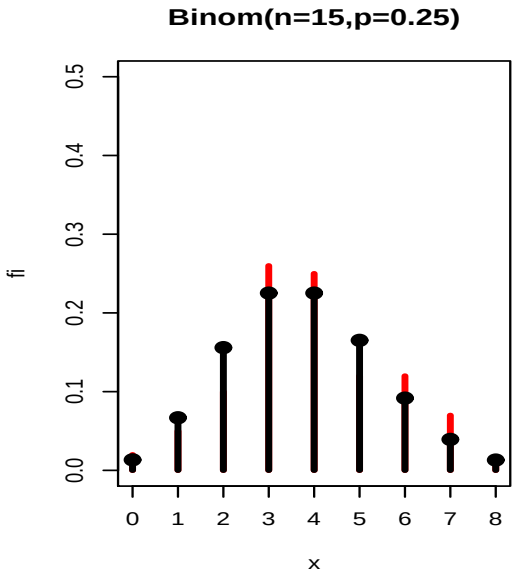

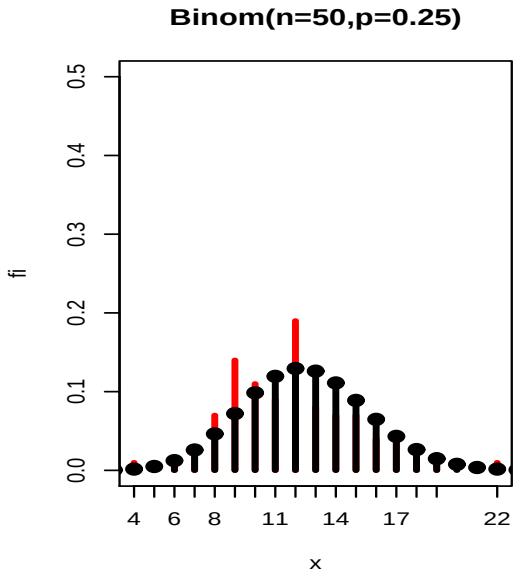

Mais modelos de probabilidade

No 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 $\boldsymbol{X \frown BN(k, p)}$

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

A distribuição binomial negativa

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

Valores $x = 0, 1, 2, ...$

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 $X \frown BN(k, p)$

$E[X] = \frac{k\,q}{p}$ $\qquad$ $Var[X] = \frac{kq}{p^2}$

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 1^{o} sucesso, a variável X diz-se ter **distribuição Geométrica**, $X \frown Geo(p)$

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

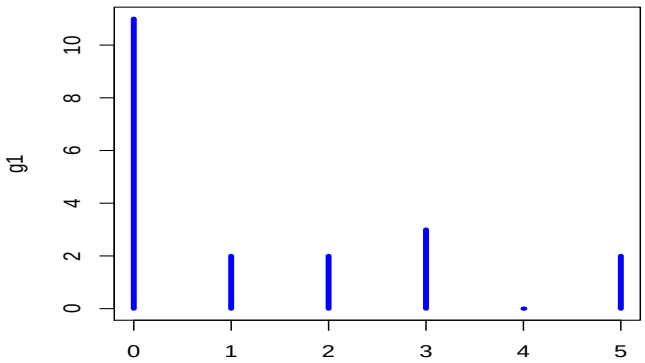

A distribuição de Poisson

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 $\lambda \longrightarrow$ número médio de sucessos que ocorrem no intervalo de tempo (ou na região especificada).

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

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

A distribuição de Poisson

Valor médio e variância

$E[X] = \lambda \qquad Var[X] = \lambda.$

Uso do

```
> 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.

A distribuição normal ou de Gauss

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

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

$$-\infty < x < +\infty, \qquad -\infty < \mu < +\infty, \qquad 0 < \sigma < +\infty$$

A distribuição normal ou de Gauss

Propriedades da curva densidade da distribuição normal

1. É simétrica relativamente a μ.
2. É uma curva unimodal, a moda é μ.
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, $Z \frown \mathcal{N}(0, 1)$

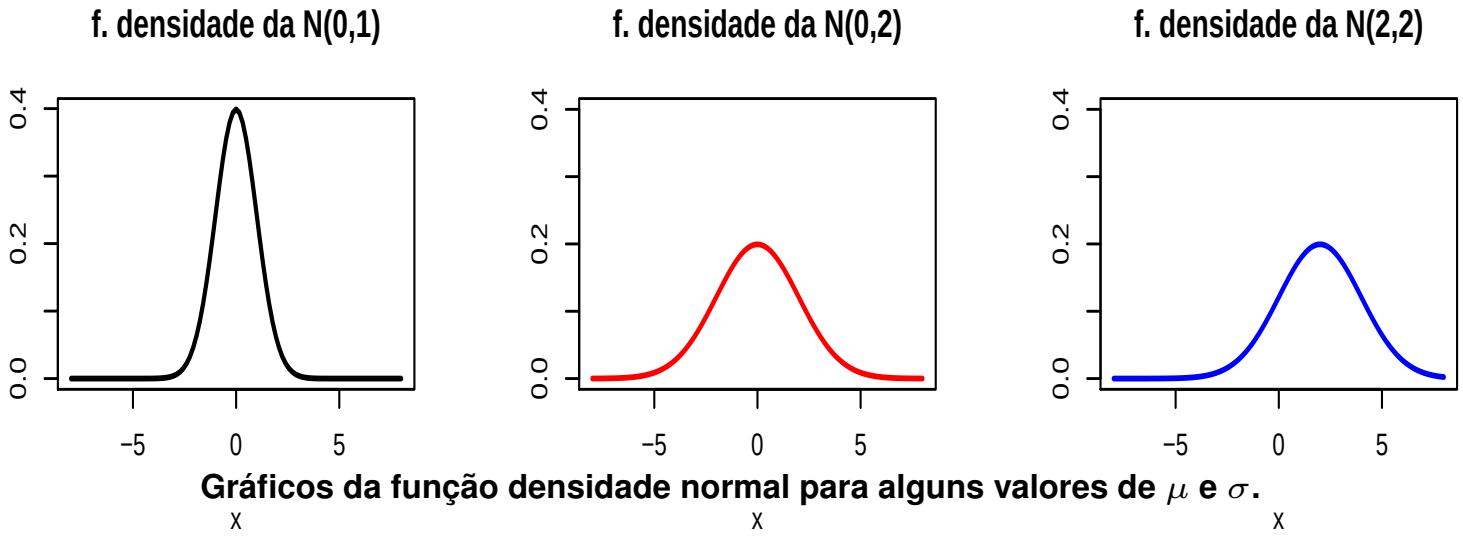

Gráficos da função densidade normal para alguns valores de μ e σ.

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)
```

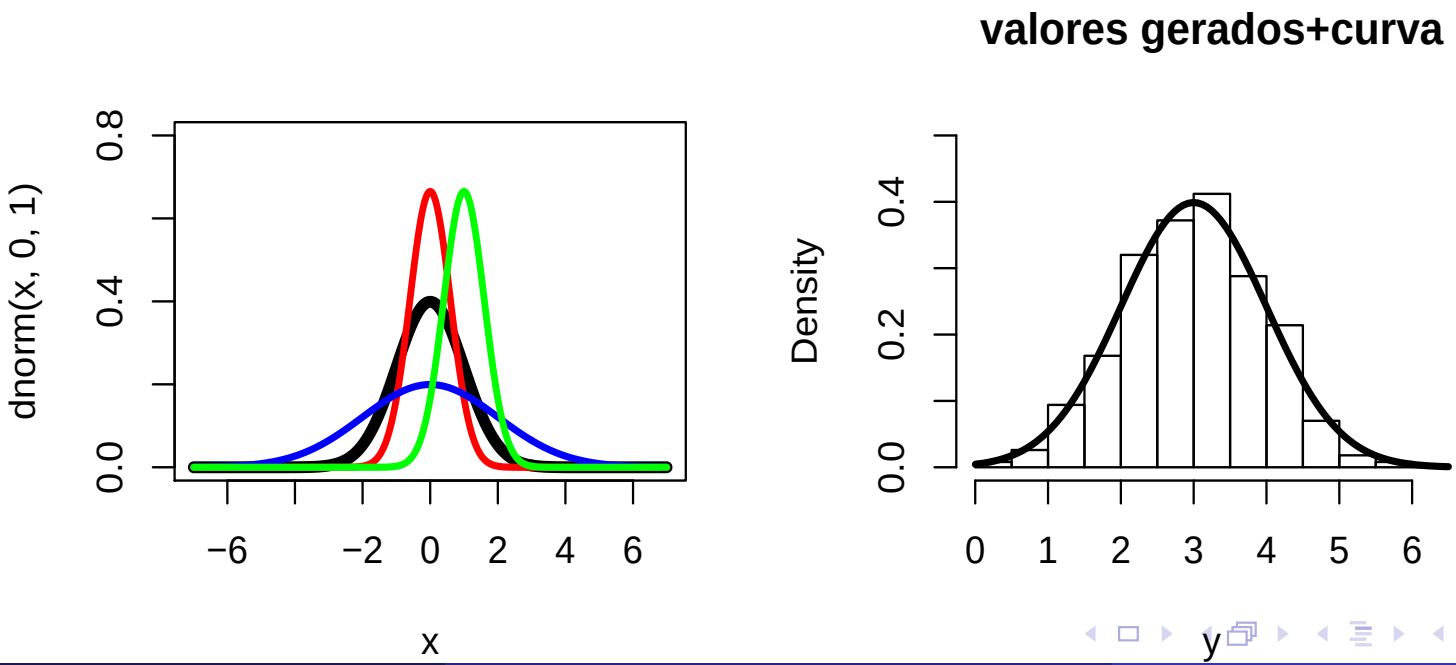

Resultados importantes com a distribuição normal

- Seja $X \frown \mathcal{N}(\mu, \sigma)$ então a v.a. $\dfrac{X-\mu}{\sigma}$ tem distribuição normal reduzida, i.e., $Z = \dfrac{X-\mu}{\sigma} \frown \mathcal{N}(0,1)$.

- Sejam X_i n v.a. normais independentes e semelhantes, i.e., tendo todas o mesmo valor médio μ e a mesma variância σ^2.

  As variáveis aleatórias soma e média, definidas respectivamente como $S_n = \sum_{i=1}^{n} X_i$ e $\overline{X}_n = \frac{1}{n}\sum_{i=1}^{n} X_i$

  têm distribuição normal assim definida
  $S_n \frown \mathcal{N}(n\mu, \sigma\sqrt{n})$ e $\overline{X}_n \frown \mathcal{N}(\mu, \sigma/\sqrt{n})$.

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

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

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

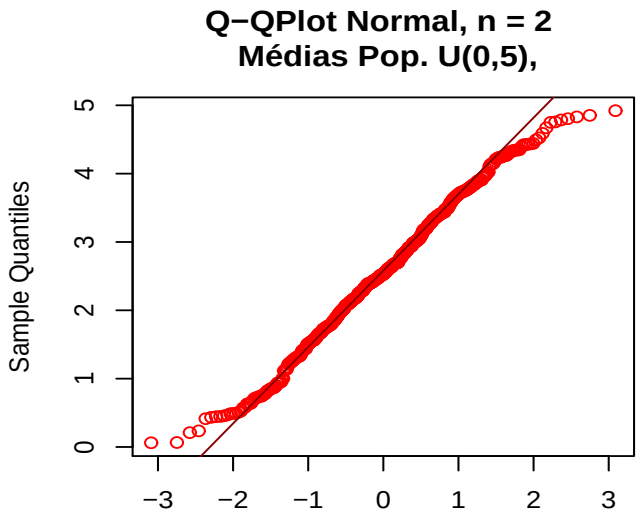

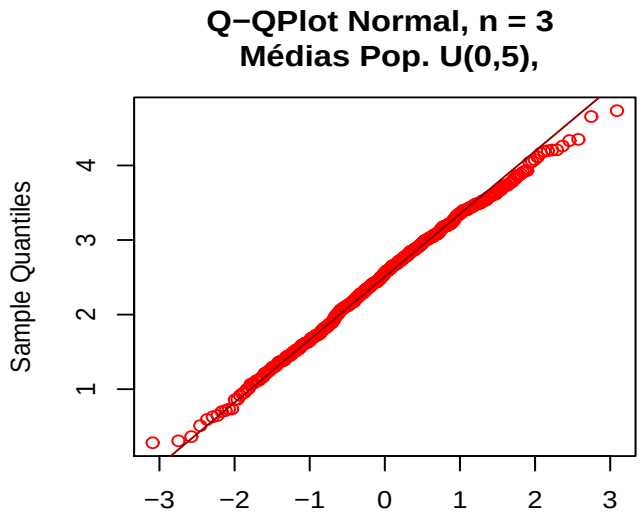

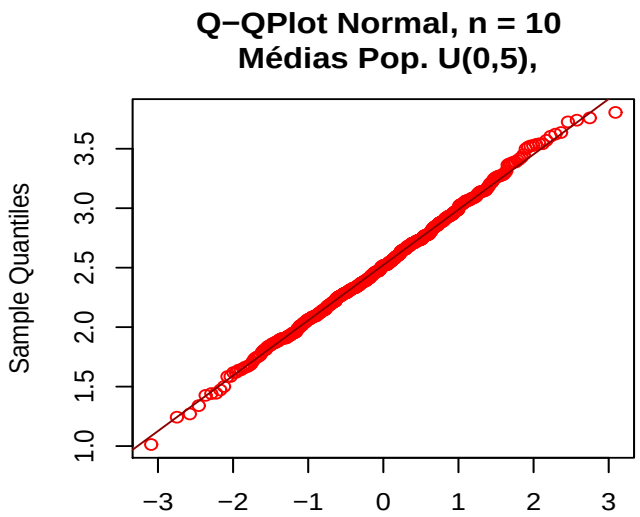

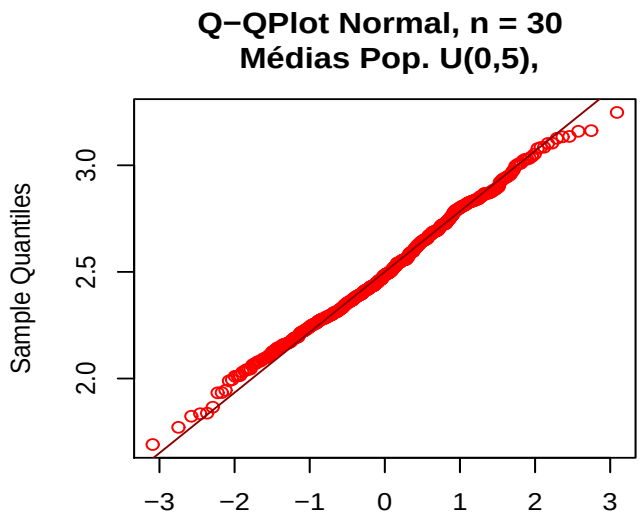

Aplicações do Teorema Limite Central

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

$X \frown \mathcal{B}(n,p)$, portanto $\mu = np$ e $\sigma^2 = npq$

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

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

Aplicações do Teorema Limite Central

$X \frown P(\lambda)$

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

Mais uma convergência

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

Outras distribuições contínuas

Distribuição uniforme contínua (já referida atrás)

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

... distribuição 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)
```

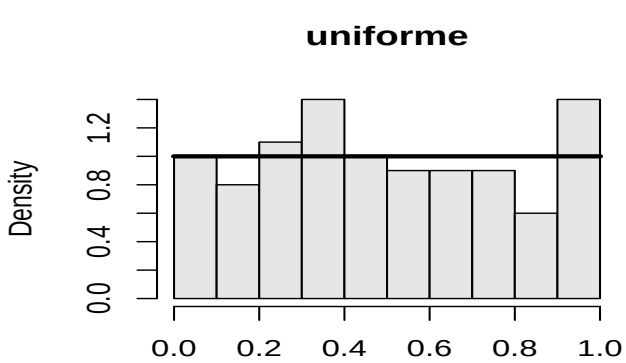

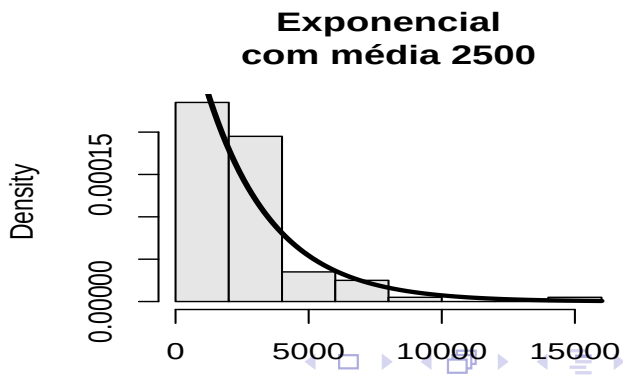

A distribuição gama

Em muitas áreas há ainda muitas situações em que a lei de Gauss não serve para modelar o fenómeno.
Comecemos por referir brevemente a **distribuição gama** que deve o seu nome à **função gama**, estudada em muitas áreas da matemática, assim definida:

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

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

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

A distribuição gama

Mais algumas propriedades da função gama:

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

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

Alguns valores particulares das derivadas úteis em muitas aplicações são

$\Gamma'(1) = \gamma = 0.57722...$valor é designado por **constante de Euler**
$\Gamma''(1) = \gamma^2 + \pi^2/6 = 1.97811...$

A distribuição gama

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

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

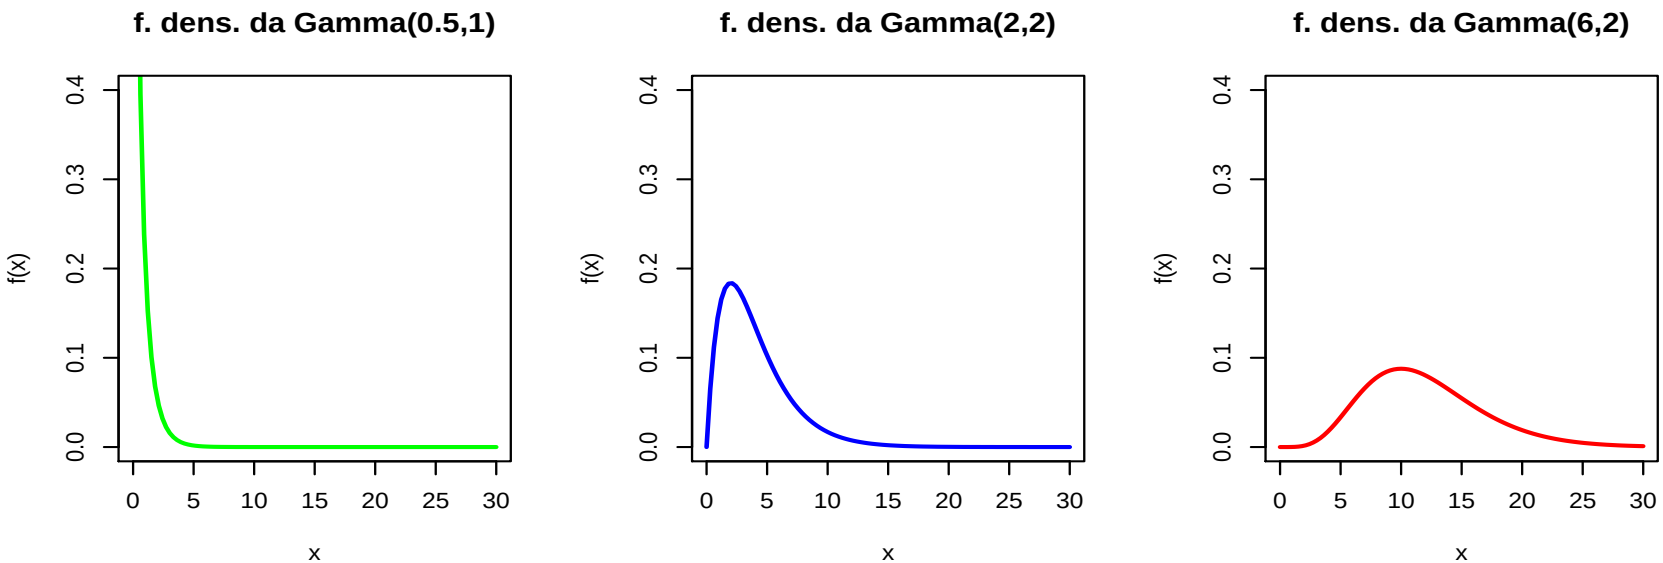

Gráficos da função densidade de uma v.a. com distribuição $G(1/2, 1)$, $G(2, 2)$ e $G(6, 2)$, da esquerda para a direita, respectivamente.

A distribuição gama

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

$E[X] = \alpha\,\beta \qquad Var[X] = \alpha\,\beta^2$

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 $X \frown Exp(\beta)$ e a função densidade é assim definida,

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

A distribuição exponencial

Valor médio e variância

$E[X] = \beta$ $\qquad$ $Var[X] = \beta^2$

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, $i = 1, ..., n$ são variáveis aleatórias independentes e semelhantes, com distribuição $Exp(\beta)$, então

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

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 λ. Seja T a v.a. que designa o tempo de espera pela ocorrência do primeiro acontecimento, então T tem distribuição exponencial, $T \frown Exp[\beta)$, 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 $X \frown Be(m, n)$ se a sua função densidade é da forma

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

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. $B(\frac{1}{2},\frac{1}{2}) = \pi$
4. $B(m,n) = \int_0^{+\infty} \frac{x^{m-1}}{(1+x)^{m+n}}\,dx$

Valor médio e variância da distribuição beta

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

A distribuição beta

A função densidade da v.a. com distribuição beta apresenta, como dissémos, 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 $(m-1)(n-1) \leqslant 0 \Rightarrow$ forma de J
– se $m = n \Rightarrow$ simetria relativamente a 0.5.

A distribuição beta

Nas figuras seguintes, vejam-se alguns desses aspectos:

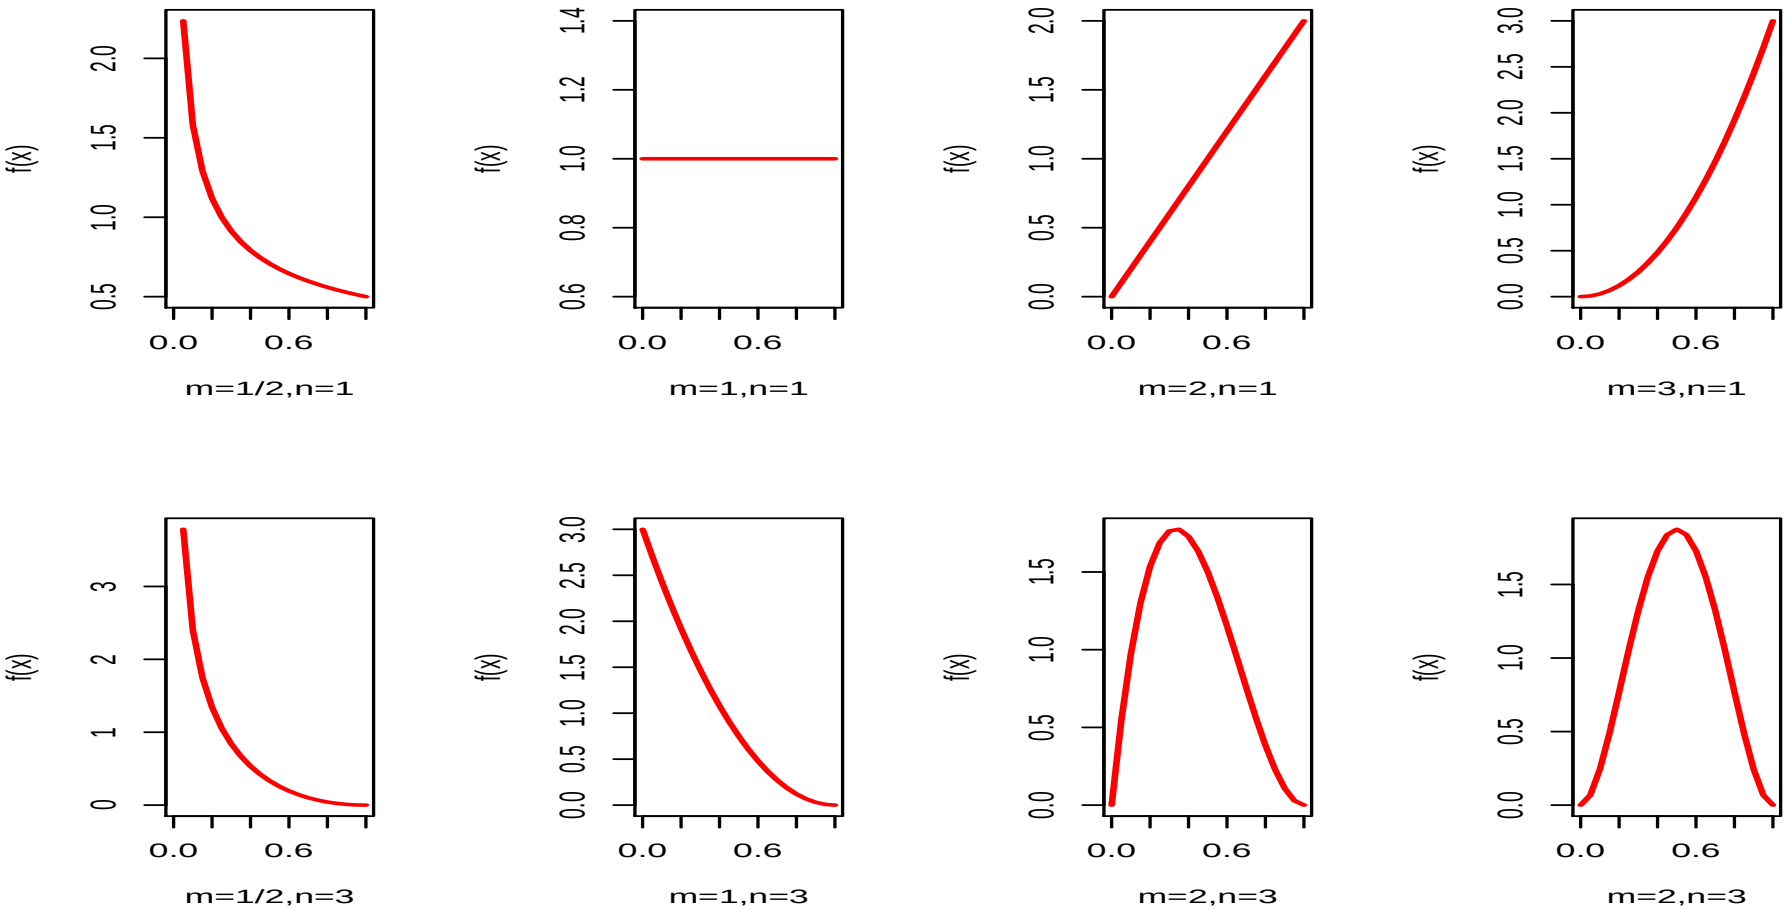

A distribuição beta

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

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

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

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

RESUMO de algumas distribuições no R

Nome da distribuição no R	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

A Teoria de valores extremos

A Teoria de Valores Extremos (EVT, do inglês *Extreme Value Theory*) é um ramo da estatística e da teoria das probabilidades que se dedica ao estudo do comportamento das caudas das distribuições de probabilidade, ou seja, dos eventos raros e extremos que se situam nos limites superiores ou inferiores das distribuições.

Ao contrário de abordagens estatísticas tradicionais que se concentram na média ou na variância, a EVT foca-se na modelação e previsão de eventos extremos, como cheias catastróficas, colapsos financeiros ou falhas estruturais críticas, entre muitos outros exemplos.

A Teoria de valores extremos

- A EVT (inícios do século XX) é uma área da estatística que apresenta características diferentes das outras áreas preocupa-se com – valores que ocorrem nas caudas da distribuição
- desenvolve técnicas e modelos para descrever e prever o não usual mais do que o usual.
- fornece um conjunto de modelos que permitem fazer a extrapolação a partir de níveis observados para níveis não observados

A Teoria de valores extremos

- EVT – teve os seus inícios no início da primeira parte do sé. XX.
  - **Emil Gumbel** foi o pioneiro das aplicações em TVE
  - Em *Statistics of Extremes (1958; 2004)* Ele apresenta várias aplicações da Teoria do Valores Extremos (EVT) a problemas do mundo real na engenharia e em fenómenos meteorológicos. Surgem primeiro aplicações na hidrologia...

A Teoria de valores extremos

- EVT – teve os seus inícios no início da primeira parte do sé. XX.
  - **Emil Gumbel** foi o pioneiro das aplicações em TVE
  - Em *Statistics of Extremes (1958; 2004)* Ele apresenta várias aplicações da Teoria do Valores Extremos (EVT) a problemas do mundo real na engenharia e em fenómenos meteorológicos. Surgem primeiro aplicações na hidrologia...

Porquê EVT?

Gumbel escreveu ...

- *“Il est impossible que l’improbable n’arrive jamais.”*
- *“Il y aura toujours une valeur qui dépassera toutes les outres.”*
- *“It seems that the rivers know the theory. It only remains to convince the engineers of the validity of this analysis”*

A Teoria de valores extremos

Algumas Aplicações A EVT é amplamente aplicada em diversas áreas, tais como:

- Hidrologia: para prever cheias e secas extremas;
- Engenharia: no dimensionamento de estruturas para resistir a cargas extremas;
- Finanças: na avaliação de riscos de perdas significativas em mercados voláteis;
- Ciências Ambientais: na análise de eventos climáticos extremos, como ondas de calor ou tempestades intensas.

Porquê a Teoria de Valores Extremos?

As principais questões a ter em consideração são essencialmente as seguintes:

- Usualmente existem poucas observações na cauda da distribuição.
- São requeridas estimativas muito para além do máximo observado.
- Necessitamos de recorrer a modelos para a cauda, usualmente baseados em resultados assintóticos.

Porquê EVT?

Quando lidamos com uma aplicação e o interesse está centrado em dados afastados da parte central, a análise dos valores extremos requer uma atenção especial e modelos específicos.

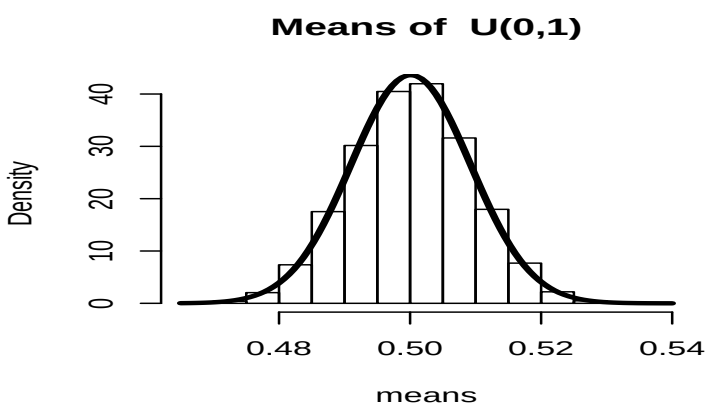

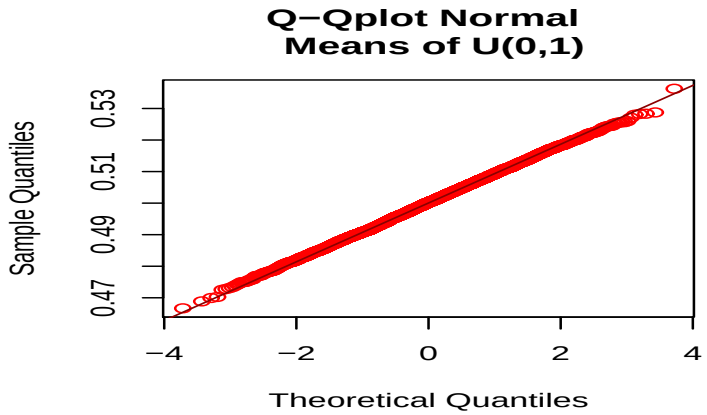

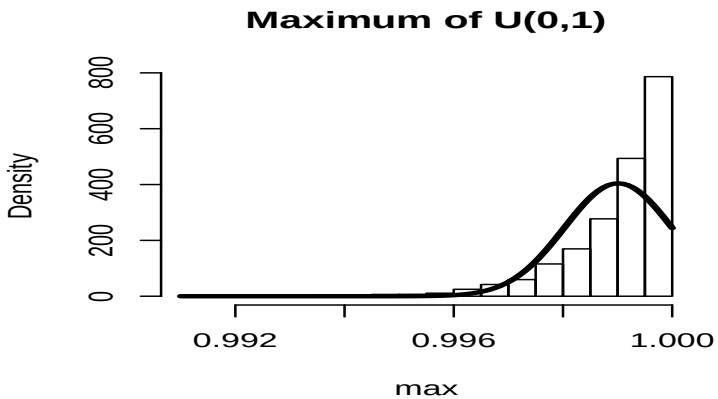

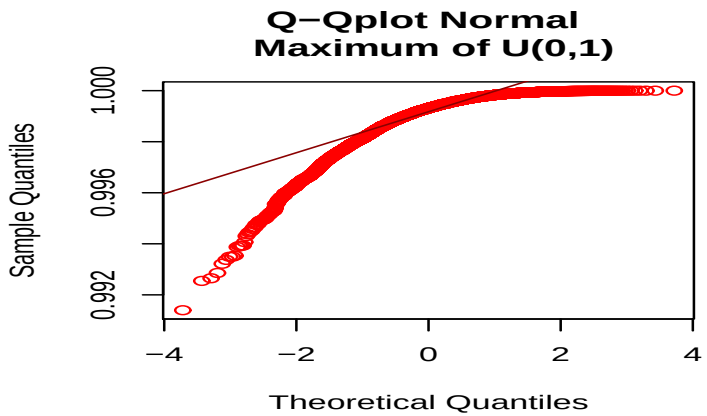

Ajustamento normal e gráficos de probabilidade para a média e o máximo de amostras aleatórias ($n = 1000$) proveniente de

Alguns livros de referência

- Statistics of Extremes, Gumbel (1958, 2004)
- Statistical Extremes and Applications, Tiago de Oliveira (ed.)(1983)
- An Introduction to Statistical Modelling of Extreme Values, Coles (2001)
- Extreme Values and Related Models with Applications in Engineering and Science, Castillo *et* al. (2005);
- Statistics of Extremes. Theory and Applications, Beirlant *et* al.(2005)
- Análise de Valores Extremos: Uma Introdução, Ivette Gomes *et* al.(2013)
- Forecasting and Assessing Risk of Individual Electricity Peaks, M. Jacob, C. Neves & D. V. Greetham, *Springer Briefs in Mathematics of Planet Earth. Weather, Climate, Oceans* (2020).

EVT – uma revisão

Notações

- $(X_1, X_2, ..., X_n) \Longrightarrow$ i.i.d. ou possivelmente variáveis aleatórias estacionárias e fracamente dependentes de uma distribuição desconhecida c.d.f. F.
- $X_{1:n} \leq X_{2:n} \leq ... \leq X_{n:n} \Longrightarrow$ são as estatísticas ordinais ascendentes associadas a $(X_1, X_2, ..., X_n)$
- Se o interesse reside nos máximos

$$M_n := max(X_1, ..., X_n)$$

Nota: Regra geral trabalhamos com o máximo mas há uma "espécie de simetria" para os mínimos

$$\min\left(X_1, \cdots, X_n\right) = -\max\left(-X_1, \cdots, -X_n\right)$$

Principais resultados limite

Haverá alguma distribuição ou famílias de distribuições limite para o máximo e para o mínimo mesmo no caso de F não ser conhecida? E, no caso afirmativo, como a(s) obter? Ora

$$F_n(x) = P[M_n \leq x] = P[X_1 \leq x, X_2 \leq x, ..., X_n \leq x] = F^n(x)$$

e

$$F_1(x) = P[m_n \leq x] = 1 - P[X_1 > x, X_2 > x, ..., X_n > x] = 1 - [1 - F(x)]^n.$$

Então tem-se

$$F_n(x) \to \begin{cases} 0, & F(x) < 1 \\ 1 & F(x) = 1, \end{cases} \qquad F_1(x) \to \begin{cases} 0, & F(x) = 0 \\ 1 & F(x) > 0, \end{cases}$$

pelo que a lei limite é degenerada.

Principais resultados limite

Recorde-se que o mesmo problema surge quando se estuda o comportamento assintótico da média $\overline{X}_n$ de n variáveis $X_1, X_2, ..., X_n$ iid com média μ e variância σ^2 finita, que sabemos convergir quase certamente para μ. O teorema limite central resolveu esta situação permitindo a obtenção de uma lei limite não degenerada, pois

$$P\left[\frac{\overline{X}_n - \mu}{\sigma/\sqrt{n}} \leq x\right] \longrightarrow \Phi(x), \quad \text{quando} \quad n \to \infty$$

sendo $\Phi(x)$ a função de distribuição da normal padrão.

Principais resultados limite

- Primeiros resultados – devidos a Fréchet(1927), Fisher & Tippet(1928), Gumbel (1935) e von Mises (1936)

- Gnedenko (1943) e de Haan (1970) deram condições para a existência de sucessões $\{a_n\} \in \mathbb{R}^+$ e $\{b_n\} \in \mathbb{R}$ tais que, quando $n \to \infty$ e $\forall x \in \mathbb{R}$,

$$\lim_{n\to\infty} P\left(\frac{M_n - b_n}{a_n} \leq x\right) = \lim_{n\to\infty} F^n(a_n x + b_n) = G_\xi(x)$$

  G_ξ é uma função de distribuição não degenerada.

G_ξ é a função de distribuição **Generalizada de Valores Extremos** , dada por

A distribuição GEV

$$G_\xi(x) \equiv \mathrm{GEV}_\xi = \begin{cases} \exp[-(1+\xi x)^{-1/\xi}], & 1+\xi x > 0 \quad \text{if} \quad \xi \neq 0 \\ \exp[-\exp(-x)], & x \in \mathbb{R} \qquad\qquad\quad \text{if} \quad \xi = 0, \end{cases}$$

Esses modelos também podem incorporar parâmetros de localização (λ) e escala ($\delta > 0$), e geralmente representamos por

$$G_\xi(x; \lambda, \delta) \equiv G_\xi((x-\lambda)/\delta)$$

Quando o limite acima é válido, dizemos que F está no domínio de atração (para máximos) de G_ξ e escrevemos $F \in \mathcal{D}_\mathcal{M}(G_\xi)$. Podemos considerar, quando o tamanho da amostra $n \longrightarrow \infty$, a aproximação

$$P[M_n \leq x] = F^n(x) \approx G_\xi((x-b_n)/a_n).$$

A distribuição GEV

O parâmetro de forma ξ é chamado de índice de valor extremo (EVI), é o principal parâmetro de interesse na análise de EVT.

O G_ξ incorpora os 3 tipos (Fisher-Tippett):

- Gumbel: $\xi = 0$ a cauda direita é do tipo exponencial, e F tem um infinito ou um finito *extremidade direita*;
- Fréchet: $\xi > 0$, a cauda direita é pesada, de um tipo polinômio negativo, e F tem um infinito *extremidade direita*;
- Weibull: $\xi < 0$, a cauda direita é leve, e F tem um finito *extremidade direita* ($x^* < +\infty$).

Formas de distribuição GEV e sua aplicabilidade

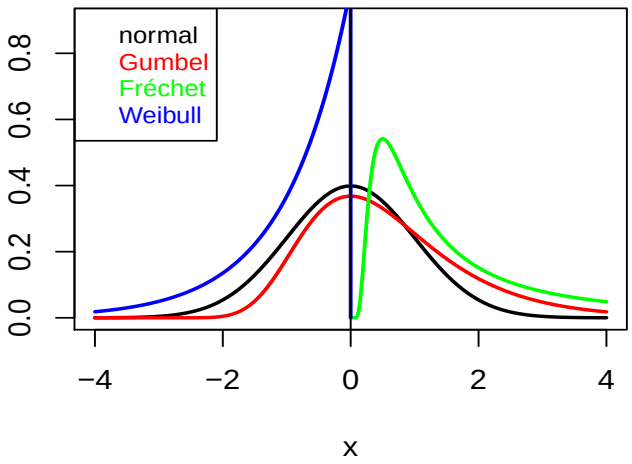

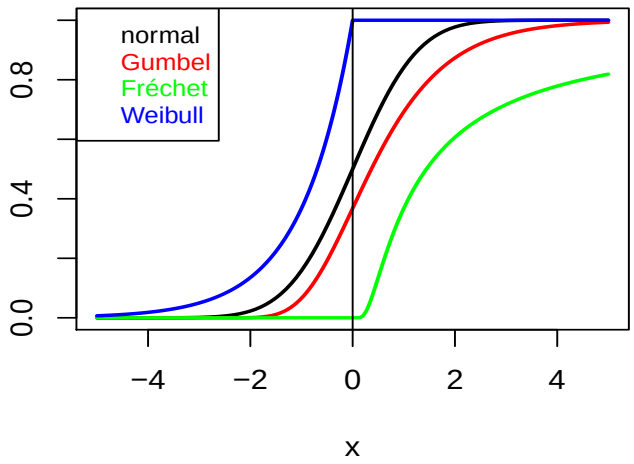

Os máximos de quase todas as distribuições contínuas comuns, após normalização adequada, convergem para o GEV, para algum valor de ξ. Alguns exemplos são:

- Weibull $\Longleftarrow$ uniforme, beta
- Gumbel $\Longleftarrow$ normal, lognormal, hiperbólica, gama, qui-quadrado
- Fréchet $\Longleftarrow$ Pareto, Cauchy, gama inversa, t de Student, loggamma