

# Introdução ao R

## MATF14 - Estatística Econômica I

Rodney Fonseca

30/10/2024

# Introdução

# Software R

R é uma linguagem e um ambiente para computação estatística e para preparação de gráficos

## **Vantagens**

- ▶ software gratuito
- ▶ métodos para simulação probabilística e cálculo de probabilidades
- ▶ diversos tipos de técnicas para análise de dados
- ▶ ferramentas gráficas

## Referências

- ▶ Livro Frery, Cribari-Neto (2011) *Elementos de Estatística Computacional Usando Plataformas de Software Livre/Gratuito*
- ▶ Página do curso de *Ciência de dados* da profa. Carolina Mota e prof. Gilberto Sassi do DEst-UFBA:  
<https://ufba.netlify.app/paginas/catalogo>
- ▶ Página do curso *Estatística Computacional com R* do prof. Paulo Justiniano (UFPR) e equipe:  
<http://cursos.leg.ufpr.br/ecr/index.html>

# Ambiente do RStudio

Botão para rodar

Lista de variáveis

Resultado

```
1+1
[1] 2
```

Environment

Environment is empty

Violent Crime Rates by US State

Description

This data set contains statistics, in arrests per 100,000 residents for assault, murder, and rape in each of the 50 US states in 1973. Also given is the percent of the population living in urban areas.

Usage

```
USArrests
```

Format

A data frame with 50 observations on 4 variables.

[,1] Murder	numeric	Murder arrests (per 100,000)
[,2] Assault	numeric	Assault arrests (per 100,000)
[,3] UrbanPop	numeric	Percent urban population
[,4] Rape	numeric	Rape arrests (per 100,000)

## Comandos básicos

# Operações básicas

## Adição

```
1+1
```

```
## [1] 2
```

## Subtração

```
5 - 3
```

```
## [1] 2
```

## Multiplicação

```
2 * 3
```

```
## [1] 6
```

## Divisão

```
10/5
```

```
## [1] 2
```

# Operações básicas

## Potência

```
2^4
```

```
## [1] 16
```

## Logaritmo (natural)

```
log(10)
```

```
## [1] 2.302585
```

## Exponencial

```
exp(3)
```

```
## [1] 20.08554
```



# Operadores lógicos

## Maior/menor que

```
5 > 3
```

```
## [1] TRUE
```

```
3 >= 3
```

```
## [1] TRUE
```

```
3 > 3
```

```
## [1] FALSE
```

# Operadores lógicos

## Igual

```
5 == 3
```

```
## [1] FALSE
```

```
3 == 3
```

```
## [1] TRUE
```

## Diferente

```
4 != 2
```

```
## [1] TRUE
```

```
4 != 4
```

```
## [1] FALSE
```

# Tipos de dados em R

## Número real

```
class(0.5)
```

```
## [1] "numeric"
```

## Valor lógico

```
class(TRUE)
```

```
## [1] "logical"
```

## Caractere

```
class('UFBA')
```

```
## [1] "character"
```

# Variável

- ▶ É como uma caixa nomeada. Você pode trocar o conteúdo da caixa, mas o nome permanece o mesmo.

Usamos os símbolos `<-` ou `=` para atribuir valores a uma variável

```
x <- 2
```

Para ver o valor da variável, basta rodar o seu nome

```
x
```

```
## [1] 2
```

# Variável

Podemos fazer operações com a variável

```
5 * x
```

```
## [1] 10
```

podemos trocar o seu valor

```
x <- 20
```

```
x
```

```
## [1] 20
```

Podemos atribuir o valor de operações à outras variáveis

```
idade <- 2 * x
```

```
idade
```

```
## [1] 40
```

# Funções

- ▶ Em matemática, funções recebem um ou mais argumentos e retornam um ou mais valores. Funções em R são similares.

## Função para criar uma sequência de 9 números

```
seq(from = 1, to = 9)
```

```
## [1] 1 2 3 4 5 6 7 8 9
```

## Fatorial de n

```
factorial(5)
```

```
## [1] 120
```

# Funções

- ▶ Em matemática, funções recebem um ou mais argumentos e retornam um ou mais valores. Funções em R são similares.

## Função para criar uma sequência de 9 números

```
seq(from = 1, to = 9)
```

```
## [1] 1 2 3 4 5 6 7 8 9
```

## Fatorial de n

```
factorial(5)
```

```
## [1] 120
```

## Coeficiente binomial (combinação)

```
choose(5,2)
```

```
## [1] 10
```

## Vetores

- ▶ Vetores são listas indexadas de *variáveis do mesmo tipo*. É como um armário de gavetas numeradas como 1, 2, 3, ... Você pode mudar o conteúdo da gaveta 5 sem alterar o conteúdo da gaveta 1.

Vetores podem ser criados com a fórmula `c(x1, x2, ...)`

```
meu_vetor <- c(1, 2, 5, 8, 1, 3)
```



## Vetores

- ▶ Vetores são listas indexadas de *variáveis do mesmo tipo*. É como um armário de gavetas numeradas como 1, 2, 3, ... Você pode mudar o conteúdo da gaveta 5 sem alterar o conteúdo da gaveta 1.

Vetores podem ser criados com a fórmula `c(x1, x2, ...)`

```
meu_vetor <- c(1, 2, 5, 8, 1, 3)
```

Valores de elementos de um vetor podem ser vistos assim

```
meu_vetor[3]
```

```
## [1] 5
```

## Vetores

- ▶ Vetores são listas indexadas de *variáveis do mesmo tipo*. É como um armário de gavetas numeradas como 1, 2, 3, ... Você pode mudar o conteúdo da gaveta 5 sem alterar o conteúdo da gaveta 1.

Vetores podem ser criados com a fórmula `c(x1, x2, ...)`

```
meu_vetor <- c(1, 2, 5, 8, 1, 3)
```

Valores de elementos de um vetor podem ser vistos assim

```
meu_vetor[3]
```

```
## [1] 5
```

Podemos alterar elementos do vetor

```
meu_vetor[3] <- 1
```

```
meu_vetor
```

```
## [1] 1 2 1 8 1 3
```

# Vetores

## Soma dos elementos de um vetor

```
sum(meu_vetor)
```

```
## [1] 16
```

## Produto dos elementos de um vetor

```
prod(meu_vetor)
```

```
## [1] 48
```

## Aplicando uma função aos elementos

```
log(meu_vetor)
```

```
## [1] 0.0000000 0.6931472 0.0000000 2.0794415 0.0000000 1.
```

## Variáveis aleatórias no software R

## Funções para variáveis aleatórias

- ▶ R conta com funções para simulação e cálculo de probabilidades de diversas variáveis aleatórias: Bernoulli, binomial, geométrica, Poisson, normal, etc.
- ▶ Exemplos de funções: gerador de valores aleatórios, função de probabilidade, função de distribuição acumulada, etc.

# Funções para variáveis aleatórias

- ▶ R conta com funções para simulação e cálculo de probabilidades de diversas variáveis aleatórias: Bernoulli, binomial, geométrica, Poisson, normal, etc.
- ▶ Exemplos de funções: gerador de valores aleatórios, função de probabilidade, função de distribuição acumulada, etc.
- ▶ Vamos explorar algumas destas funções para as distribuições Bernoulli e binomial

# Distribuição Bernoulli

- ▶ Relembrando: a distribuição Bernoulli é usada para modelar experimentos com dois resultados possíveis, *sucesso* ou *fracasso*, em que a probabilidade de sucesso é  $p \in [0, 1]$
- ▶ Se  $X \sim \text{Bernoulli}(p)$ , então  $X \in \{0, 1\}$  e  $X$  assume valor 1 com probabilidade  $p = P(X = 1)$ .
- ▶ Temos ainda que  $E(X) = p$  e  $\text{var}(X) = p(1 - p)$

# Distribuição Bernoulli

- ▶ Relembrando: a distribuição Bernoulli é usada para modelar experimentos com dois resultados possíveis, *sucesso* ou *fracasso*, em que a probabilidade de sucesso é  $p \in [0, 1]$
- ▶ Se  $X \sim \text{Bernoulli}(p)$ , então  $X \in \{0, 1\}$  e  $X$  assume valor 1 com probabilidade  $p = P(X = 1)$ .
- ▶ Temos ainda que  $E(X) = p$  e  $\text{var}(X) = p(1 - p)$
- ▶ Note que também podemos dizer que  $X \sim \text{Bin}(1, p)$



## Distribuição Bernoulli

- ▶ Podemos usar a função `rbinom(n_amostras, 1, p)` para gerar valores de  $X \sim \text{Bernoulli}(p)$ , em que *n\_amostras* é o número de realizações simuladas de  $X$

## Distribuição Bernoulli

- ▶ Podemos usar a função `rbinom( $n\_amostras$ , 1,  $p$ )` para gerar valores de  $X \sim \text{Bernoulli}(p)$ , em que  $n\_amostras$  é o número de realizações simuladas de  $X$
- ▶ Ex.: Gerando 10 valores de  $X \sim \text{Bernoulli}(1/4)$ :

```
amostra_bern <- rbinom(10, 1, 1/4)
amostra_bern
```

```
## [1] 0 0 0 0 1 0 0 0 0 0
```

# Distribuição Bernoulli

- ▶ Podemos montar tabelas para checar a frequência dos valores gerados

## Tabela de frequências absolutas

```
table(amostra_bern)
```

```
## amostra_bern  
## 0 1  
## 9 1
```

## Tabela de frequências relativas

```
table(amostra_bern)/10
```

```
## amostra_bern  
## 0 1  
## 0.9 0.1
```

# Distribuição Bernoulli

- ▶ Calculando a média amostral dos valores

```
mean(amostra_bern)
```

```
## [1] 0.1
```

- ▶ Calculando a variância amostral dos valores

```
var(amostra_bern)
```

```
## [1] 0.1
```

# Distribuição Bernoulli

- ▶ Calculando a média amostral dos valores

```
mean(amostra_bern)
```

```
## [1] 0.1
```

- ▶ Calculando a variância amostral dos valores

```
var(amostra_bern)
```

```
## [1] 0.1
```

**Observação:** as funções *mean* e *var* não fornecem os valores teóricos, somente estimativas com base na amostra gerada

## Distribuição Bernoulli

- ▶ Para calcular probabilidades, podemos usar a função **dbinom(k, 1, p)**. O exemplo abaixo fornece  $P(X = 1)$ :

```
dbinom(1, 1, 1/4)
```

```
## [1] 0.25
```

# Distribuição Bernoulli

- ▶ Para calcular probabilidades, podemos usar a função **dbinom(k, 1, p)**. O exemplo abaixo fornece  $P(X = 1)$ :

```
dbinom(1, 1, 1/4)
```

```
## [1] 0.25
```

- ▶ A função de distribuição acumulada  $F(t) = P(X \leq t)$  é **pbinom(t, 1, p)**. O exemplo abaixo fornece  $P(X \leq 1/2)$ :

```
pbinom(1/2, 1, 1/4)
```

```
## [1] 0.75
```

## Distribuição Bernoulli

- ▶ Vamos considerar um exemplo com 1000 valores simulados

```
amostra_maior_bern <- rbinom(1000, 1, 1/4)
table(amostra_maior_bern)/1000
```

```
## amostra_maior_bern
##      0      1
## 0.759 0.241
```

- ▶ As frequências ficam mais próximas das probabilidades teóricas



## Distribuição Bernoulli

- ▶ Vamos considerar um exemplo com 1000 valores simulados

```
amostra_maior_bern <- rbinom(1000, 1, 1/4)
table(amostra_maior_bern)/1000
```

```
## amostra_maior_bern
##      0      1
## 0.759 0.241
```

- ▶ As frequências ficam mais próximas das probabilidades teóricas
- ▶ A média teórica é  $E(x) = p = 0.25$ , enquanto a amostral foi

```
mean(amostra_maior_bern)
```

```
## [1] 0.241
```

- ▶ Quanto maior a amostra de valores gerados for, mais próxima a média amostral será da média teórica (populacional).

# Distribuição Binomial

- ▶ Relembrando: a distribuição binomial conta o número de sucessos em  $n$  repetições de experimentos de Bernoulli com probabilidade  $p$  de sucesso
- ▶ Se  $X \sim \text{Bin}(n, p)$ , então  $X \in \{0, 1, \dots, n\}$  e  $X$  assume valor  $k \in \{0, 1, \dots, n\}$  com probabilidade

$$P(X = k) = \binom{n}{k} p^k (1 - p)^{n-k}$$

- ▶ Temos ainda que  $E(X) = np$  e  $\text{var}(X) = np(1 - p)$

## Distribuição Binomial

- ▶ A função  $rbinom(n\_amostras, n, p)$  para gerar valores de  $X \sim Bin(n, p)$ , em que  $n\_amostras$  é o número de realizações simuladas de  $X$ , enquanto  $n$  e  $p$  são os parâmetros da distribuição binomial

## Distribuição Binomial

- ▶ A função `rbinom(n_amostras, n, p)` para gerar valores de  $X \sim \text{Bin}(n, p)$ , em que  $n\_amostras$  é o número de realizações simuladas de  $X$ , enquanto  $n$  e  $p$  são os parâmetros da distribuição binomial
- ▶ Ex.: Gerando 10 valores de  $X \sim \text{Bin}(5, 1/2)$ :

```
amostra_bin <- rbinom(10, 5, 1/2)
amostra_bin
```

```
## [1] 3 1 2 3 3 2 4 3 3 4
```

Tabela de frequência dos valores gerados

```
table(amostra_bin)
```

```
## amostra_bin
## 1 2 3 4
## 1 2 5 2
```

## Distribuição Binomial

- ▶  $X \sim \text{Bin}(n, p)$ , podemos calcular a probabilidade  $P(X = k)$  usando a função **dbinom(k, n, p)**.
- ▶ No exemplo abaixo, consideramos que  $X \sim \text{Bin}(5, 1/2)$  e calculamos  $P(X = 3)$ :

```
dbinom(3, 5, 1/2)
```

```
## [1] 0.3125
```

- ▶ Usando a fórmula teórica  $P(X = 3) = \binom{5}{3} \left(\frac{1}{2}\right)^3 \left(\frac{1}{2}\right)^{5-3}$ , tal cálculo seria

```
choose(5, 3) * ( (1/2)^3 ) * ( (1/2)^(5 - 3) )
```

```
## [1] 0.3125
```

# Distribuição Binomial

- ▶ Vamos gerar uma amostra grande de  $X \sim \text{Bin}(5, 1/2)$ :

```
tam_amostra <- 1000000  
vx <- rbinom(tam_amostra, 5, 1/2)  
table(vx)/tam_amostra
```

```
## vx  
##      0      1      2      3      4      5  
## 0.031465 0.156483 0.312334 0.312410 0.156142 0.031166
```

- ▶ A média amostral dessa amostra é

```
mean(vx)
```

```
## [1] 2.498779
```

enquanto a média teórica é  $E(X) = np = 5 * (1/2) = 2.5$ .