

PROGRAMAÇÃO

1. Conceitos Básicos do R

Rita P. Ribeiro

Mestrado em Informática Médica

Curso de Especialização em Informática da Saúde

2016/2017



FACULDADE DE MEDICINA
UNIVERSIDADE DO PORTO



FACULDADE DE CIÊNCIAS
UNIVERSIDADE DO PORTO


Programa

1. Conceitos Básicos do R
2. Manipulação de Dados
3. Sumarização de Dados
4. Visualização de Dados
5. Geração de Relatórios

Introdução ao R

RStudio

Um IDE para o R. Livre. Funciona em Windows, Mac e Linux



Introdução ao R

Interação básica com a consola

- ▶ A forma mais comum de interação com o R é através da sua linha de comando
 - ▶ O utilizador digita um comando
 - ▶ Pressiona a tecla ENTER
 - ▶ O R “devolve” a resposta
- ▶ É também possível guardar um conjunto de comandos num ficheiro (tipicamente com a extensão `.R`) e depois pedir ao R para executar todos os comandos no ficheiro de uma vez

Introdução ao R

Interação básica com a consola (2)

- Podemos usar a linha de comando como uma simples calculadora

```
1+3/5*6^2
```

```
## [1] 22.6
```

- Podemos tirar partido das inúmeras funções disponíveis na linguagem R

```
rnorm(5,mean=30,sd=10)
```

```
## [1] 22.30537 22.67923 49.71342 32.47532 47.48740
```

```
mean(sample(1:1000,30)) # composição de funções
```


```
## [1] 547.2
```

Introdução ao R

Interação básica com a consola (3)

- Podemos produzir gráficos

```
plot(sample(1:10,5),sample(1:10,5),  
      main="Desenhando 5 pontos aleatórios",  
      xlab="X",ylab="Y")
```



Variáveis e Objetos

- ▶ Tal como acontece em outras linguagens de programação, o R permite a atribuição de **objetos** a **variáveis**:

```
<variavel> <- <objeto>
```

- ▶ Estes objetos poderão ser de diferentes tipos (p.ex. um número, texto, uma expressão numérica, uma chamada a uma função, uma tabela de dados, um gráfico, etc.).
- ▶ Uma vez feita a atribuição, o interpretador do R irá substituir o nome da variável pelo seu conteúdo.

```
x <- 10
x
## [1] 10
x * 2
## [1] 20
```

Variáveis e Objetos

Atribuição

- Uma variável pode guardar o resultado da avaliação de uma expressão

```
pesoKg <- 60
pesoLb <- pesoKg * 2.20462
pesoLb
## [1] 132.2772
```

- **Nota:** a atribuição (<-) é destrutiva!
- Isto significa que se atribuírmos a uma variável, que já guarda um objeto, um novo objeto, só este último será guardado sendo o anterior perdido.

```
pesoLb <- 120
pesoLb
## [1] 120
```


Variáveis e Objetos

Tipos Básicos de Dados

Os objetos em R possuem dois atributos intrínsecos:

- ▶ **mode**: indica o tipo básico do conteúdo do objeto
 - ▶ `numeric` (p.ex. 5, 6.3, 10.344, -2.3, -7)
 - ▶ `character` (p. ex. "olá", "está um belo dia")
 - ▶ `logical` (TRUE, FALSE)
 - ▶ etc.
- ▶ **length**: indica o número de elementos contidos no objeto

```
x <- 10
mode(x)

## [1] "numeric"

length(x)

## [1] 1
```

```
mode("ola")

## [1] "character"

mode(ola)

## Error in mode(ola):
object 'ola' not found
```

```
mode(TRUE)

## [1] "logical"

mode(true)

## Error in mode(true):
object 'true' not found
```

Variáveis e Objetos

Tipos de Objetos de Dados

- ▶ No R, existem 7 tipos principais de objetos e que se caracterizam pelo tipo de dados que podem conter:

objeto	tipo de dados (mode)	vários tipos?
vector	numeric, character, complex, logical	não
matrix	numeric, character, complex, logical	não
array	numeric, character, complex, logical	não
list	numeric, character, complex, logical, function, expression, ...	sim
data.frame	numeric, character, complex, logical	sim
factor	numeric, character	não
ts	numeric, character, complex, logical	não

- ▶ Mais à frente, iremos ver em mais detalhe cada um deles.

Variáveis e Objetos

Alguns Operadores

- Uma variável pode guardar o resultado de uma expressão composta por um conjunto de operadores.

Aritméticos		Comparação		Lógicos	
+	adição	<	menor	!x	negação
-	subtração	>	maior	x&y	conjunção
*	multiplicação	<=	menor ou igual	x&& y	conjunção (<i>lazy</i>)
/	divisão	>=	maior ou igual	x y	disjunção
^	potência	==	igual	x y	disjunção (<i>lazy</i>)
%%	resto	!=	diferente	xor(x, y)	disjunção excl.
%/%	divisão inteira				

```
15 %% 2^2 * 10
```

```
## [1] 30
```

```
(15 %% 2)^2 * 10
```

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

```
4 == 5
```

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

```
4 != 5
```

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

```
TRUE & (4 > 5)
```

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

```
TRUE & !(4 > 5)
```

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

Funções

- ▶ Em R a maioria das coisas que podemos fazer são levadas a cabo por funções.
- ▶ Uma função é um objeto que recebe um conjunto de zero ou mais objetos de entrada (argumentos ou parâmetros) e devolve um outro objeto.
- ▶ O R disponibiliza um conjunto de funções.

```
log(1.5) # calcula o logaritmo na base e
## [1] 0.4054651

sin(pi/2) # calcula o seno
## [1] 1

sqrt(25) # calcula a raiz quadrada
## [1] 5
```

Funções

Criar Novas Funções

- ▶ Podemos também criar novas funções para automatizar operações frequentes.
 - ▶ Podemos, por exemplo, criar uma função, que dado um peso em lbs e um valor de conversão nos fornece o peso em kgs.

```
lb2kg <- function(p,conv) p*conv  
lb2kg(100,0.453592)  
## [1] 45.3592
```

- ▶ Também podemos indicar que alguns dos parâmetros têm **valores por omissão**

```
lb2kg <- function(p,conv=0.453592) p*conv  
lb2kg(100)  
## [1] 45.3592
```

Funções

Composição de Funções

- ▶ A composição de funções é uma noção importante na matemática
 - $(f \circ g)(x) = f(g(x))$ significa aplicar a função f ao resultado de aplicar a função g a x
- ▶ O R é uma linguagem funcional; podemos usar a composição de funções como forma de realizar operações complexas sem termos que armazenar os resultados intermédios
- ▶ Exemplo: duas soluções para calcular $e^{\sqrt{10}}$

sem composição de funções

```
x <- 10
temp <- sqrt(x)
y <- exp(temp)
y
## [1] 23.62434
```

com composição de funções

```
x <- 10
y <- exp(sqrt(x))
y
## [1] 23.62434
```

Tipos de Objetos de Dados

objeto	tipo de dados (mode)	vários tipos?
vector	numeric, character, complex, logical	não
array	numeric, character, complex, logical	não
matrix	numeric, character, complex, logical	não
list	numeric, character, complex, logical, function, expression, ...	sim
data.frame	numeric, character, complex, logical	sim
factor	numeric, character	não
ts	numeric, character, complex, logical	não

Vetores

- ▶ Um vetor é uma classe de objetos que contém informação sobre **um conjunto de valores do mesmo tipo básico de dados**
 - p.ex. os preços de uma série de produtos vendidos numa loja
- ▶ Se um conjunto de valores partilha algo de comum e são do mesmo tipo básico de dados, pode fazer sentido guardá-los sob a forma de um vetor
- ▶ Um vetor é mais um exemplo de um objecto que podemos guardar numa variável do R

Vetores

Criação

- ▶ Vamos criar um vetor com os pesos de 5 indivíduos

```
pesos <- c(62.6,55.4,70.2,75,68.1)
pesos

## [1] 62.6 55.4 70.2 75.0 68.1
```

- ▶ No lado direito da atribuição temos uma chamada à função `c()` usando como argumentos os valores dos pesos que queremos guardar como um vetor
- ▶ A função `c()`, de *combine*, pega nos seus argumentos e produz como resultado um vetor contendo esses valores

Vetores

Criação (2)

- ▶ A função `c()` permite-nos associar nomes aos membros do vetor.
- ▶ No exemplo anterior poderia fazer sentido associar a cada valor o nome do indivíduo,

```
pesos <- c(Marco=62.6,Filipe=55.4,Valter=70.2,Nuno=75,João=68.1)
```

- ▶ Isto torna o significado do vetor mais claro, e como iremos ver, vai facilitar o acesso à informação guardada no vetor.


```
pesos
##  Marco Filipe Valter   Nuno   João
##   62.6   55.4   70.2   75.0   68.1
```

Vetores

Criação (3)

- ▶ Para além de mais claro, o uso de nomes é também recomendado porque o R tira partido destes nomes em várias situações.
- ▶ Este é o caso da maioria das funções que produzem gráficos:

```
barplot(pesos)
```



Vetores

Geração

- Podemos gerar vetores a partir de sequências regulares

- operador :

```
# inteiros entre 1 e 10
1:10

## [1] 1 2 3 4 5 6 7 8 9 10
```

- função rep()

```
# 10 repetições do valor 1
rep(1,10)

## [1] 1 1 1 1 1 1 1 1 1 1

# 10 repetições do vetor c(1,2)
rep(c(1,2),10)

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

Vetores

Geração (2)

- Podemos gerar vetores a partir de sequências regulares (cont.)

- função `seq()`

```
# inteiros ímpares entre 1 e 10
seq(1,10,by=2)

## [1] 1 3 5 7 9

# ...
seq(1,5,length=9)

## [1] 1.0 1.5 2.0 2.5 3.0 3.5 4.0 4.5 5.0
```

- etc.

Vetores

Geração (3)

- ▶ Podemos gerar vetores a partir de sequências aleatórias

- ▶ função `sample()`

```
# 5 pontos entre os inteiros de 1 a 10  
sample(1:10,size=5)  
## [1] 10  9  3  6  1
```

- ▶ função `rnorm()`

```
# 5 pontos a partir de uma Distribuição Normal  
rnorm(5,mean=0,sd=1)  
## [1]  0.5443721  1.0296054 -0.2986404  1.1542553  1.9433560
```

- ▶ função `runif()`

```
# 5 pontos a partir de uma Distribuição Uniforme  
runif(5,min=0,max=1)  
## [1] 0.3575183 0.7377517 0.5200198 0.6324686 0.5809737
```

- ▶ etc.

Vetores

Indexação

- ▶ Sempre que temos objetos com vários valores (p.ex. vetores) podemos estar interessados em aceder a algum desses valores individualmente.
- ▶ Esse é o **objetivo da indexação**: *aceder a um sub-conjunto dos valores guardados numa variável*.
- ▶ Em matemática estamos habituados a usar índices. Por exemplo, x_3 normalmente representa o 3º elemento do conjunto de valores x .
- ▶ Em R a ideia é semelhante:

```
pesos <- c(Marco=62.6,Filipe=55.4,Valter=70.2,Nuno=75,João=68.1)
pesos[3]

## Valter
##      70.2
```

Vetores

Indexação (2)

- ▶ Também podemos usar os nomes das posições nos vetores para a indexação

```
pesos <- c(Marco=62.6,Filipe=55.4,Valter=70.2,Nuno=75,João=68.1)
pesos["Nuno"]

## Nuno
##      75
```

- ▶ `pesos["Nuno"]` acede à posição do vetor `pesos` indexada com o texto "Nuno".
- ▶ **Nota:** `pesos[Nuno]` acede à posição do vetor `pesos` indexada pelo conteúdo da variável `Nuno` (que não existe!).

```
pesos[Nuno]

## Error in eval(expr, envir, enclos): object 'Nuno' not found
```


Vetores

Indexação (3)

- ▶ Também podemos usar um vetor como índice e desta forma aceder a mais do que uma posição ao mesmo tempo

```
pesos <- c(Marco=62.6,Filipe=55.4,Valter=70.2,Nuno=75,João=68.1)
pesos[c(2,4)]

## Filipe    Nuno
##   55.4    75.0
```

- ▶ Estamos portanto a aceder às posições 2 e 4 do vetor `pesos`
- ▶ O mesmo se aplica a vetores de nomes

```
pesos[c("Filipe", "Nuno")]

## Filipe    Nuno
##   55.4    75.0
```

Vetores

Indexação (4)

- ▶ Também podemos usar condições lógicas para “questionar” os dados!

```
pesos[pesos > 70]  
## Valter    Nuno  
##   70.2    75.0
```

- ▶ A ideia é que o resultado da indexação serão os valores do vetor pesos em que a condição indicada é verdadeira
- ▶ O que é obtido com a seguinte instrução?

```
pesos[pesos > mean(pesos)]  
## Valter    Nuno    João  
##   70.2    75.0    68.1
```

- ▶ Este é mais um exemplo de composição de funções!

Vetores

Vetorização de Operações

- ▶ A grande maioria das funções e operadores do R podem ser aplicadas diretamente a conjuntos de valores (p.ex. vetores)
- ▶ Suponhamos que pretendemos saber os pesos anteriores em libras (lbs).

```
umKg <- 2.20462 # valor de 1kg em lb
pesos * umKg

##      Marco      Filipe      Valter      Nuno      João
## 138.0092 122.1359 154.7643 165.3465 150.1346
```

- ▶ Multiplicámos **um** número por um **conjunto** de números!
- ▶ O resultado é um outro conjunto de números que são obtidos pela multiplicação de cada número no vetor pesos por 2.20462

Vetores

Vetorização de Operações (2)

- ▶ Exemplo de vetorização de funções:

```
round(pesos)
```

##	Marco	Filipe	Valter	Nuno	João
##	63	55	70	75	68

- ▶ Ao aplicar a função `round()` a um vetor em vez de a um só número, ela vai produzir como resultado um vetor com o mesmo tamanho, resultante de aplicar a função a cada número no vetor original.

Vetores

Vetorização de Operações (3)

- ▶ Podemos fazer coisas semelhantes com dois conjuntos de números.
- ▶ Suponhamos que também temos a altura de cada um dos indivíduos:

```
alturas <- c(Marco=1.65,Filipe=1.60,Valter=1.69,Nuno=1.72,João=1.73)
alturas
```

##	Marco	Filipe	Valter	Nuno	João
##	1.65	1.60	1.69	1.72	1.73

- ▶ Podemos calcular o IMC de cada um deles:

```
IMC <- round(pesos/alturas^2,1)
IMC
```

##	Marco	Filipe	Valter	Nuno	João
##	23.0	21.6	24.6	25.4	22.8

Vetores

Vetorização de Operações (4)

- ▶ As condições lógicas com vetores que vimos anteriormente são outro exemplo de vetorização

```
pesos > 70  
## Marco Filipe Valter   Nuno   João  
## FALSE FALSE   TRUE   TRUE  FALSE
```

- ▶ Estamos a comparar os 5 pesos com um só número (70). O resultado é um vetor com os valores obtidos por cada uma das comparações. Por vezes é verdade, noutros casos é falso.
- ▶ No caso de `pesos[pesos > 70]`, a expressão de indexação é um vetor de valores booleanos cujo significado é aceder às posições onde estão os valores verdadeiros.

Vetores

Algumas Funções

► Exemplos de funções aplicáveis a vetores:

<code>max(x)</code>	máximo dos elementos de <code>x</code>
<code>mean(x)</code>	média dos elementos de <code>x</code>
<code>median(x)</code>	mediana dos elementos de <code>x</code>
<code>min(x)</code>	mínimo dos elementos de <code>x</code>
<code>prod(x)</code>	produto dos elementos de <code>x</code>
<code>range(x)</code>	intervalo de valores dos elementos de <code>x</code>
<code>round(x,n)</code>	arredonda os elementos de <code>x</code> a <code>n</code> casas decimais
<code>sort(x)</code>	ordena os elementos de <code>x</code>
<code>sum(x)</code>	soma dos elementos de <code>x</code>
<code>unique(x)</code>	os elementos de <code>x</code> sem duplicados
<code>which(x == a)</code>	o índice do elemento de <code>x</code> que é igual a <code>a</code>
<code>which.max(x)</code>	o índice do máximo dos elementos de <code>x</code>
<code>which.min(x)</code>	o índice do mínimo dos elementos de <code>x</code>
<code>...</code>	

► Algumas destas funções são apenas aplicáveis a vetores numéricos ...

Tipos de Objetos de Dados

Matrizes

objeto	tipo de dados (mode)	vários tipos?
vector	numeric, character, complex, logical	não
<code>matrix</code>	<code>numeric, character, complex, logical</code>	<code>não</code>
array	numeric, character, complex, logical	não
list	numeric, character, complex, logical, function, expression, ...	sim
data.frame	numeric, character, complex, logical	sim
factor	numeric, character	não
ts	numeric, character, complex, logical	não

Matrizes

- ▶ Como os vetores, as matrizes também podem ser usadas para guardar **conjuntos** de valores **do mesmo tipo básico de dados** que estejam de alguma forma relacionados
- ▶ Todavia as matrizes “espalham” os valores por duas dimensões: as linhas e as colunas
- ▶ Voltemos ao cenário dos pesos e alturas. Poderia fazer mais sentido guardar esta informação numa matriz em vez de em dois vetores
- ▶ As colunas poderiam corresponder ao peso e à altura e as linhas aos indivíduos.

Matrizes

Criação

- Vejamos como criar essa matriz:

```
pesoalt <- matrix(c(62.6,55.4,70.2,75,68.1,  
                    1.65,1.60,1.69,1.72,1.73),  
                  nrow=5,ncol=2)
```

- A função `matrix()` pode ser usada para criar matrizes
- Temos que lhe dar pelo menos os valores a colocar na matriz bem como o nº de linhas e/ou colunas

```
pesoalt  
  
##      [,1] [,2]  
## [1,] 62.6 1.65  
## [2,] 55.4 1.60  
## [3,] 70.2 1.69  
## [4,] 75.0 1.72  
## [5,] 68.1 1.73
```

Matrizes

Criação (2)

```
pesoalt <- matrix(c(62.6,55.4,70.2,75,68.1,  
                    1.65,1.60,1.69,1.72,1.73),  
                  nrow=5,ncol=2)
```

```
pesoalt
```

```
##      [,1] [,2]  
## [1,] 62.6 1.65  
## [2,] 55.4 1.60  
## [3,] 70.2 1.69  
## [4,] 75.0 1.72  
## [5,] 68.1 1.73
```

- ▶ O parâmetro `nrow` indica qual o número de linhas
- ▶ O parâmetro `ncol` indica o número de colunas
- ▶ Por omissão, os valores fornecidos são "espalhados" por coluna.

Matrizes

Indexação

- Semelhante aos vetores mas agora com **duas dimensões**

```
pesoalt
##      [,1] [,2]
## [1,] 62.6 1.65
## [2,] 55.4 1.60
## [3,] 70.2 1.69
## [4,] 75.0 1.72
## [5,] 68.1 1.73

pesoalt[4,2]
## [1] 1.72
```

- Também podemos obter toda uma linha ou coluna,

```
pesoalt[1,] # 1a linha
## [1] 62.60 1.65
```

```
pesoalt[,2] # 2a coluna
## [1] 1.65 1.60 1.69 1.72 1.73
```

Matrizes

Indexação (2)

- Como nos vetores também aqui podemos dar nomes às duas dimensões das matrizes

```
colnames(pesoalt) <- c("peso", "altura")
rownames(pesoalt) <- c("Marco", "Filipe", "Valter", "Nuno", "João")
pesoalt
```

##		peso	altura
##	Marco	62.6	1.65
##	Filipe	55.4	1.60
##	Valter	70.2	1.69
##	Nuno	75.0	1.72
##	João	68.1	1.73

- As funções `colnames()` e `rownames()` podem ser usadas para obter os nomes das respectivas dimensões ou para indicar quais são atribuindo-lhes vetores com os nomes.

Matrizes

Indexação (3)

- Os nomes também podem ser usados para indexação

```
pesoalt

##      peso altura
## Marco  62.6   1.65
## Filipe 55.4   1.60
## Valter 70.2   1.69
## Nuno   75.0   1.72
## João   68.1   1.73

pesoalt["Marco",]

##      peso altura
## 62.60   1.65

pesoalt["Valter", "altura"]

## [1] 1.69
```

Tipos de Objetos de Dados

Arrays

objeto	tipo de dados (mode)	vários tipos?
vector	numeric, character, complex, logical	não
matrix	numeric, character, complex, logical	não
array	numeric, character, complex, logical	não
list	numeric, character, complex, logical, function, expression, ...	sim
data.frame	numeric, character, complex, logical	sim
factor	numeric, character	não
ts	numeric, character, complex, logical	não

Arrays

Criação

- ▶ *Arrays* são extensões das matrizes para mais do que 2 dimensões
- ▶ Podemos criar um *array* com a função `array()`

```
a <- array(1:12,dim=c(2,3,2))
```

```
a
```

```
## , , 1
```

```
##
```

```
##      [,1] [,2] [,3]
```

```
## [1,]     1     3     5
```

```
## [2,]     2     4     6
```

```
##
```

```
## , , 2
```

```
##
```

```
##      [,1] [,2] [,3]
```

```
## [1,]     7     9    11
```

```
## [2,]     8    10    12
```


Arrays

Indexação

- O mesmo tipo de esquemas vistos até agora podem ser usados nos *arrays*

```
a[1,2,1]
```

```
## [1] 3
```

```
a[1,,2]
```

```
## [1] 7 9 11
```

```
a[, ,1]
```

```
##      [,1] [,2] [,3]
```

```
## [1,]    1    3    5
```

```
## [2,]    2    4    6
```

Tipos de Objetos de Dados

Listas

objeto	tipo de dados (mode)	vários tipos?
vector	numeric, character, complex, logical	não
matrix	numeric, character, complex, logical	não
array	numeric, character, complex, logical	não
list	numeric, character, complex, logical, function, expression, ...	sim
data.frame	numeric, character, complex, logical	sim
factor	numeric, character	não
ts	numeric, character, complex, logical	não

Listas

- ▶ As listas são coleções ordenadas de objetos.
- ▶ A estes objetos damos o nome de *componentes* da lista.
- ▶ As componentes de uma lista não têm que ser do mesmo tipo de dados ou tamanho, o que as torna muito flexíveis

Listas

Criação

- As listas podem ser criadas da seguinte forma:

```
lst <- list(id=43534543,nome="Marco",dados=c(peso=62.6,altura=1.65))
lst

## $id
## [1] 43534543
##
## $nome
## [1] "Marco"
##
## $dados
##   peso altura
## 62.60  1.65
```

Listas

Indexação

- Para aceder **ao conteúdo** de uma componente da lista podemos usar o seu nome,

```
lst$dados  
  
##      peso altura  
## 62.60    1.65
```

- Podemos também aceder a várias componentes ao mesmo tempo, ou seja a uma sub-lista

```
lst[c('nome', 'dados')]  
  
## $nome  
## [1] "Marco"  
##  
## $dados  
##      peso altura  
## 62.60    1.65
```

Listas

Indexação (2)

- Podemos ainda aceder às componentes individuais das listas pela sua posição na lista, ao estilo dos vetores,

```
lst[[2]]  
## [1] "Marco"
```

- Usamos **duplos parentesis retos**! Parentesis únicos teriam um outro significado no contexto das listas,

```
lst[2]  
## $nome  
## [1] "Marco"
```

- O resultado é uma lista (efetivamente uma sub-lista de `lst`), enquanto que com os parentesis duplos obtivemos o valor que está nessa componente (que neste caso é uma *string*)

Tipos de Objetos de Dados

Data Frames

objeto	tipo de dados (mode)	vários tipos?
vector	numeric, character, complex, logical	não
matrix	numeric, character, complex, logical	não
array	numeric, character, complex, logical	não
list	numeric, character, complex, logical, function, expression, ...	sim
<code>data.frame</code>	numeric, character, complex, logical	sim
factor	numeric, character	não
ts	numeric, character, complex, logical	não

Data Frames

- ▶ Os data frames são estruturas semelhantes às matrizes, mas onde as **colunas podem ser de diferentes tipos**.
- ▶ Os data frames podem ser vistos como tabelas de dados com uma linha por observação, composta por vários atributos.
- ▶ Muitos cenários são melhor representados por data frames.
- ▶ Por exemplo, o estudo de um tratamento sobre um conjunto de indivíduos.

Data Frames

Criação

- Podemos criar um data frame da seguinte forma:

```
estud <- data.frame(  
  id=c("43534543", "32456534"),  
  nome=c("Marco", "Filipe"),  
  peso=c(62.6, 55.4),  
  altura=c(1.65, 1.60)  
)
```

estud


##		id	nome	peso	altura
## 1	43534543	Marco	62.6	1.65	
## 2	32456534	Filipe	55.4	1.60	

Data Frames

Criação (2)

- Se temos demasiados dados para introduzir é mais prático fazê-lo usando um interface tipo folha de cálculo fornecido com o R,

```
> estud <- edit(estud)
```



	id	nomes	peso	altura
1	43534543	Marco	62.6	1.65
2	32456534	Filipe	55.4	1.6
3				
4				
5				

Data Frames

Indexação

- ▶ Os *data frames* são visualizados como uma tabela de dados

```
estud

##           id  nome peso altura
## 1 43534543  Marco 62.6   1.65
## 2 32456534 Filipe 55.4   1.60
```

- ▶ Os dados individuais podem ser acedidos de forma semelhante às matrizes

```
estud[2,3]

## [1] 55.4

estud[1,"nome"]

## [1] Marco
## Levels: Filipe Marco
```

Data Frames

Indexação (2)

- ▶ A função `subset()` pode ser usada para facilitar a realização de consultas aos dados

```
estud

##           id    nome peso altura
## 1 43534543  Marco 62.6   1.65
## 2 32456534 Filipe 55.4   1.60

subset(estud,peso > 60,nome)

##      nome
## 1 Marco

subset(estud,altura < 1.60,c(id,nome))

## [1] id    nome
## <0 rows> (or 0-length row.names)
```

Tipos de Objetos de Dados

Factors

objeto	tipo de dados (mode)	vários tipos?
vector	numeric, character, complex, logical	não
matrix	numeric, character, complex, logical	não
array	numeric, character, complex, logical	não
list	numeric, character, complex, logical, function, expression, ...	sim
data.frame	numeric, character, complex, logical	sim
factor	numeric, character	não
ts	numeric, character, complex, logical	não

Factors

- ▶ Um **factor** é um objeto frequentemente usado para representar variáveis categóricas.
- ▶ Para além de guardar o conjunto de valores (como num vetor), guarda também as "categorias" possíveis para essa variável, mesmo que nem todas estejam presentes nos dados.
- ▶ Por omissão, as categorias são o conjunto de valores diferentes presente nos dados.
- ▶ Em R, estas categorias são designadas por `levels`.

Factors

Criação

► Exemplos de factors:

```
factor(rep(1:3,2))

## [1] 1 2 3 1 2 3
## Levels: 1 2 3

corOlhos <- factor(c("castanha","verde","castanha","azul","castanha"),
                    levels=c("azul","castanha","verde"))
corOlhos

## [1] castanha verde    castanha azul      castanha
## Levels: azul castanha verde

levels(corOlhos)

## [1] "azul"    "castanha" "verde"
```

Tipos de Objetos de Dados

Séries Temporais

objeto	tipo de dados (mode)	vários tipos?
vector	numeric, character, complex, logical	não
matrix	numeric, character, complex, logical	não
array	numeric, character, complex, logical	não
list	numeric, character, complex, logical, function, expression, ...	sim
data.frame	numeric, character, complex, logical	sim
factor	numeric, character	não
ts	numeric, character, complex, logical	não

Séries Temporais

- ▶ Uma série temporal consiste numa coleção de observações ao longo do tempo.
- ▶ Geralmente, a sequência de observações é feita em intervalos de tempo uniformes.
- ▶ Podemos dizer que uma série temporal é uma sequência de números coletados em intervalos regulares durante um período de tempo.
- ▶ O R possui várias classes de objectos que podem ser usadas para guardar séries temporais
- ▶ Vamos usar a infra-estrutura fornecida pela *package* `xts`
Nota: esta é uma *package* extra que terá que ser instalada antes de poder ser usada.

Séries Temporais

Criação

- ▶ Em Inglaterra, foi feito um estudo sobre a evolução das listas de espera em hospitais públicos, entre 2009 e 2010. Tomemos esse exemplo.
- ▶ A função `xts()` pode ser usada para criar uma série temporal,

```
library(xts)
listaEsp <- xts(c(621506,615877,625942,633645,624284,614754),
               as.Date(c("2009-10-31","2009-11-30","2009-12-31",
                        "2010-01-31","2010-02-28","2010-03-31")))

listaEsp

##           [,1]
## 2009-10-31 621506
## 2009-11-30 615877
## 2009-12-31 625942
## 2010-01-31 633645
## 2010-02-28 624284
## 2010-03-31 614754
```

Séries Temporais

Criação (2)

- ▶ A função `xts` tem dois argumentos: a série temporal e as etiquetas temporais da mesma
- ▶ O segundo argumento terá que conter datas
- ▶ A função `as.Date()` pode ser usada para converter *strings* em datas
- ▶ Se fornecermos uma matriz como primeiro argumento da função `xts()` iremos gerar uma série multivariada em que cada coluna representa uma das variáveis a ser medida em cada instante temporal. Temos pois que fornecer tantas datas quantas as linhas da matriz.

Séries Temporais

Indexação

- Podemos indexar os objectos criados pela função `xts()` da seguinte forma,

```
listaEsp[3]  
  
##           [,1]  
## 2009-12-31 625942
```

- Todavia, é bem mais interessante fazer consultas temporais,

```
listaEsp["2010-02-28"]  
  
##           [,1]  
## 2010-02-28 624284  
  
listaEsp["2010-02"]  
  
##           [,1]  
## 2010-02-28 624284
```

Séries Temporais

Indexação (2)

```
listaEsp["2010-01-31/"]
```

```
##           [,1]
```

```
## 2010-01-31 633645
```

```
## 2010-02-28 624284
```

```
## 2010-03-31 614754
```

```
listaEsp["2010-01-31/2010-03-31"]
```

```
##           [,1]
```

```
## 2010-01-31 633645
```

```
## 2010-02-28 624284
```

```
## 2010-03-31 614754
```


- ▶ O índice é uma *string* que pode representar intervalos de datas usando o símbolo / ou omitindo parte da data. Em vez do símbolo / também é possível usar ::

Séries Temporais

Gráficos

- ▶ A função `plot()` pode ser usada para visualizar a evolução da série ao longo do tempo
- ▶ O R trata de escolher as etiquetas dos eixos mais adequadas,

```
plot(listaEsp)
```



Conversão entre Tipos de Dados

- ▶ O R oferece a possibilidade de conversão entre os tipos principais de dados.
- ▶ Existem funções que permitem verificar o tipo de dados do objeto e converter para outro tipo de dados.

<code>is.vector()</code>	<code>as.vector()</code>
<code>is.numeric()</code>	<code>as.numeric()</code>
<code>is.character()</code>	<code>as.character()</code>
<code>is.matrix()</code>	<code>as.matrix()</code>
<code>is.list()</code>	<code>as.list()</code>
<code>is.data.frame()</code>	<code>as.data.frame()</code>
<code>is.factor()</code>	<code>as.factor()</code>
<code>is.xts()</code>	<code>as.xts()</code>

Conversão entre Tipos de Dados

Alguns Exemplos

- Conversão de um vetor de valores numéricos para valores de texto

```
v <- c(1,2,2,3,4,4,5)
v
## [1] 1 2 2 3 4 4 5
```

```
as.character(v)
## [1] "1" "2" "2" "3" "4" "4" "5"
```

- Conversão de um vetor de valores numéricos para um factor

```
v <- c(1,2,2,3,4,4,5)
v
## [1] 1 2 2 3 4 4 5
```

```
as.factor(v)
## [1] 1 2 2 3 4 4 5
## Levels: 1 2 3 4 5
```


Conversão entre Tipos de Dados

Alguns Exemplos (2)

► Conversão de um vetor para uma lista

```
v <- letters[1:2]
v
## [1] "a" "b"
```

```
as.list(v)
## [[1]]
## [1] "a"
##
## [[2]]
## [1] "b"
```

► Conversão de uma lista para um vetor.

```
l <- list("a"=1,"b"=2)
l
## $a
## [1] 1
##
## $b
## [1] 2
```

```
as.numeric(l)
## [1] 1 2
```

Valores Especiais

- ▶ NA
- ▶ NULL
- ▶ Inf e -Inf
- ▶ NaN

Valores Especiais

NA

- ▶ Quando colecionamos um conjunto de valores, nem sempre temos a garantia de que todos eles serão conhecidos.
- ▶ Sempre que um valor não é conhecido, o R atribui-lhe um valor especial: `NA` (Not Available).
- ▶ O resultado de qualquer operação envolvendo um `NA` é também `NA`.

```
v <- c(23,18,NA,21,19)
v*2

## [1] 46 36 NA 42 38

mean(v)

## [1] NA
```

Valores Especiais

NA (2)

- ▶ A função `is.na()` retorna o valor TRUE para os valores NA.

```
v <- c(23,18,NA,21,19)
is.na(v)

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

- ▶ Podemos, limitar a aplicação de uma função, por exemplo, aos casos que não são NA.

```
v <- c(23,18,NA,21,19)
mean(v[!is.na(v)])

## [1] 20.25

mean(v, na.rm=TRUE)

## [1] 20.25
```

Valores Especiais

NA (3)

- ▶ O valor NA também pode decorrer de uma conversão de tipos que não seja possível...

```
as.numeric("A")  
  
## Warning: NAs introduced by coercion  
## [1] NA
```

- ▶ ... ou da indexação de um valor inexistente.

```
v <- 1:4  
v[10]  
  
## [1] NA
```

Valores Especiais

NULL

- ▶ Existe também um outro tipo de valor especial que o R usa para representar o nulo: `NULL`
- ▶ `NULL` é frequentemente usado em argumentos em funções para representar o facto de nenhum valor ter sido passado a esse argumento.
- ▶ A função `is.null()` retorna o valor `TRUE` para os valores `NULL`.

```
f <- function(x=NULL) is.null(x)
f(2)

## [1] FALSE

f()

## [1] TRUE
```

- ▶ Nota: `NULL` $\neq$ `NA`

Valores Especiais

Inf e -Inf

- ▶ O computador tem uma capacidade para a representação de valores numéricos que é finita.
- ▶ Se o resultado de um cálculo for demasiado grande, O R retorna `Inf` para representar $+\infty$ e `-Inf` para representar $-\infty$.

```
2^1024  
## [1] Inf  
  
5/0  
## [1] Inf
```

- ▶ A função `is.infinite()` retorna o valor TRUE para os valores `Inf` ou `-Inf`.

```
is.infinite(5/0)  
## [1] TRUE
```

Valores Especiais

NaN

- ▶ Existe um outro tipo de valor especial que é produzido por cálculos numéricos: **NaN** (Not a Number)

```
0/0  
## [1] NaN  
  
Inf - Inf  
## [1] NaN
```

- ▶ A função `is.nan()` retorna o valor TRUE para os valores NaN.

```
is.nan(0/0)  
## [1] TRUE  
  
is.nan(Inf - Inf)  
## [1] TRUE
```


Instruções de Controlo de Fluxo

- ▶ O interpretador do R executa as instruções sequencialmente.
- ▶ As instruções são agrupadas em bloco usando chavetas `{}`; o uso de chavetas é opcional no caso de existir apenas uma instrução.
- ▶ O valor de um grupo de instruções é o resultado da última expressão avaliada.
- ▶ Quando pretendemos alterar o fluxo de execução dos blocos de instruções, podemos recorrer a:
 - ▶ instruções de execução condicional (`if-else`, `switch`);
 - ▶ instruções de execução em ciclo (`for`, `while`) .

Instruções de Controlo de Fluxo

Execução Condicional: if-else

```
if(cond) expr
```

```
if(cond) expr1 else expr2
```

```
calcIMC <- function(peso,altura) {  
  imc <- peso/altura^2  
  if(imc < 19.1)  
    print("abaixo do peso")  
  else  
    if(imc >= 19.1 & imc <= 25.8)  
      print("peso normal")  
    else  
      print("acima do peso")  
}
```

```
calcIMC(55,1.70)  
  
## [1] "abaixo do peso"  
  
calcIMC(70,1.70)  
  
## [1] "peso normal"  
  
calcIMC(85,1.70)  
  
## [1] "acima do peso"
```

Instruções de Controlo de Fluxo

Execução Condicional: switch

```
switch(expr, ...)
```

```
calcula <- function(funcao,x) {  
  fx <- switch(funcao,  
    "media" = mean(x),  
    "mediana" = median(x),  
    "desviopad" = sd(x)  
  )  
  print(paste("resultado = ",fx))  
}
```

```
calcula("media",1:10)  
  
## [1] "resultado = 5.5"  
  
calcula("desviopad",1:10)  
  
## [1] "resultado = 3.02765035409749"  
  
calcula("mediana",1:10)  
  
## [1] "resultado = 5.5"
```

Instruções de Controlo de Fluxo

Execução em Ciclo: for

```
for (var in seq) expr
```

```
parimparF <- function(vals) {  
  n <- length(vals)  
  for(i in 1:n) {  
    if(vals[i] %% 2 == 0)  
      print(paste(vals[i], "é par"))  
    else  
      print(paste(vals[i], "é ímpar"))  
  }  
}
```

```
parimparF(1:4)  
  
## [1] "1 é ímpar"  
## [1] "2 é par"  
## [1] "3 é ímpar"  
## [1] "4 é par"  
  
parimparF(sample(10,5))  
  
## [1] "1 é ímpar"  
## [1] "2 é par"  
## [1] "7 é ímpar"  
## [1] "4 é par"  
## [1] "8 é par"
```

Instruções de Controlo de Fluxo

Execução em Ciclo: while

```
while (cond) expr
```

```
parimparW <- function(vals) {  
  n <- length(vals)  
  i <- 1  
  while(i <= n) {  
    if(vals[i] %% 2 == 0)  
      print(paste(vals[i], " é par"))  
    else  
      print(paste(vals[i], " é ímpar"))  
    i <- i + 1  
  }  
}
```

```
parimparW(1:4)  
  
## [1] "1 é ímpar"  
## [1] "2 é par"  
## [1] "3 é ímpar"  
## [1] "4 é par"  
  
parimparW(sample(10,5))  
  
## [1] "9 é ímpar"  
## [1] "5 é ímpar"  
## [1] "10 é par"  
## [1] "7 é ímpar"  
## [1] "1 é ímpar"
```

Ainda sobre Funções

Âmbito das Variáveis

- ▶ As variáveis definidas dentro da função são **variáveis locais**, isto é, não são visíveis fora da função. Os parâmetros de uma função também são variáveis locais.
- ▶ As variáveis definidas fora das funções são **variáveis globais** e são sempre visíveis.

```
calcIMC <- function(peso,altura) {
  imc <- peso/altura^2
  if(imc < 19.1)
    print("abaixo do peso")
  else
    if(imc >= 19.1 & imc <= 25.8)
      print("peso normal")
    else
      print("acima do peso")
}
```

```
p <- 60; a <- 1.65
calcIMC(p,a)

## [1] "peso normal"

p # variável global

## [1] 60

imc # variável local de calcIMC

## Error in eval(expr, envir,
enclos): object 'imc' not found
```

Ainda sobre Funções

Valor de Retorno

- ▶ O valor de retorno de uma função pode ser um qualquer objeto em R.
- ▶ Esse valor é explicitado pela função `return()`. Esta função faz com que a execução da função **termine, de imediato**, e retorne o valor indicado para o ponto onde foi chamada a função.
- ▶ No caso de não existir a chamada à função `return()`, o R retorna o valor da última expressão avaliada na execução da função.

```
f <- function(x,a=1,b=2) {  
  return(a*x + b)  
}  
f(4)  
## [1] 6
```

```
f <- function(x,a=1,b=2) {  
  a*x + b  
}  
f(4)  
## [1] 6
```

Ainda sobre Funções

Valor de Retorno (2)

- ▶ Numa função só pode existir um valor de retorno.
- ▶ Se desejarmos retornar mais do que um valor, podemos colecionar os valores de retorno num objeto (vetor, lista, etc.) e, depois, retornar esse objeto.

```
f <- function(x,a=1,b=2) {  
  y <- a*x + b  
  c(x=x,y=y)  
}  
f(4)  
  
## x y  
## 4 6
```


Ainda sobre Funções

Vetorização de Funções

- ▶ Vimos que o R, tal como qualquer linguagem de programação, possui instruções de ciclo.
- ▶ Contudo, comparativamente a outras linguagens de programação, estas instruções de ciclo são muito menos utilizadas em R.
- ▶ O R oferece uma alternativa mais eficiente: a vetorização de operações e também de funções.
- ▶ A vetorização de funções permite a aplicação de uma função aos elementos de um dado tipo de objeto.
- ▶ A diferença a nível de eficiência é, especialmente, notória para grandes quantidades de dados.

Ainda sobre Funções

Vetorização de Funções: *apply*

- ▶ A função `apply(X,MARGIN,FUN,...)` permite a aplicação de uma função (FUN) a um array ou matriz (X) por linha (MARGIN=1), coluna (MARGIN=2) ou ambas (MARGIN=c(1,2)).

```
m <- matrix(1:8,nrow=2,ncol=4,
            byrow=TRUE)
```

```
m
```

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

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

```
## [2,]    5    6    7    8
```

```
apply(m,1,sum) # por linha
```

```
## [1] 10 26
```

```
apply(m,2,sum) # por coluna
```

```
## [1]  6  8 10 12
```

```
parimpar <- function(x) {
  if(x %% 2 == 0)
    return("par")
  else
    return("ímpar")
}
```

```
apply(m,c(1,2),parimpar)
```

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

```
## [1,] "ímpar" "par"  "ímpar" "par"
```

```
## [2,] "ímpar" "par"  "ímpar" "par"
```

Ainda sobre Funções

Vetorização de Funções: *lapply*

- ▶ A função `lapply(X,FUN,...)` aplica uma dada função (FUN) sobre cada um dos elementos de uma lista, data frame ou vetor X e retorna os resultados numa lista.

```
l <- list(a="Ola",b=3:7,
          c=data.frame(X=10:11,Y=LETTERS[10:11]))
l
## $a
## [1] "Ola"
##
## $b
## [1] 3 4 5 6 7
##
## $c
##      X Y
## 1 10 J
## 2 11 K
```

```
lapply(l,mode)
## $a
## [1] "character"
##
## $b
## [1] "numeric"
##
## $c
## [1] "list"
```

Ainda sobre Funções

Vetorização de Funções: *sapply*

- ▶ A função `sapply(X,FUN,...)` é semelhante à `lapply()`, mas tenta simplificar o resultado a uma estrutura de dados. mais elementar.

```
l <- list(a="Ola",b=3:7,c=data.frame(X=10:11,Y=LETTERS[10:11]))
sapply(l,mode)

##           a           b           c
## "character"  "numeric"  "list"

sapply(1:8,parimpar)

## [1] "ímpar" "par"   "ímpar" "par"   "ímpar" "par"   "ímpar" "par"
```