

PROGRAMAÇÃO

2. Manipulação de Dados

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

Tabelas de Dados em Data Frames

- ▶ Tipicamente, as tarefas de análise de dados assentam sobre conjuntos de dados sob a forma de tabela onde:
 - ▶ as linhas representam observações;
 - ▶ as colunas representam atributos que caracterizam as observações.
- ▶ Em R usam-se *data frames* para guardar estas tabelas de dados.
- ▶ Como podemos **importar dados** de diferentes origens e/ou formatos para *data frames*?
- ▶ Como podemos facilmente **manipular os dados** contidos nestes *data frames*?

Importação de Dados

Dados Internos ao R

- ▶ O R inclui vários conjuntos de dados (*data sets*). Cada *package* pode também incluir novos conjuntos de dados.
- ▶ A lista de *data sets* pode ser obtida executando:

```
# datasets carregados
data()
# datasets da package MASS
data(package = "MASS")
# datasets das packages instaladas
data(package = .packages(all.available = TRUE))
```

- ▶ Para carregar um data set:

```
# carregar apenas o dataset
data(Pima.tr, package="MASS")
## carregar todo o package
library(MASS)
data(Pima.tr)
```

Importação de Dados

Ficheiros RData

- ▶ Qualquer objeto R e, portanto, qualquer *data frame* pode ser guardado num ficheiro RData.

```
dados <- data.frame(X=rnorm(3),Y=rnorm(3))  
save(dados,file="exp.RData")
```

- ▶ O objeto guardado no ficheiro RData pode ser novamente carregado para o R.

```
rm(dados) # remove o objeto df da memória  
dados  
  
## Error in eval(expr, envir, enclos): object 'dados' not found  
  
load("exp.RData") # carrega o objeto contido no ficheiro  
dados  
  
##           X           Y  
## 1 -0.6023181 -1.8427645  
## 2  0.6380087 -1.6670012  
## 3 -0.5526226  0.2369833
```

Importação de Dados

Ficheiros de Texto

- ▶ Muitas vezes, os *data sets* encontram-se guardados em ficheiros de texto onde:
 - ▶ cada observação do *data set* é representada por uma linha de texto;
 - ▶ o valor de cada atributo da observação é delimitada por um caracter separador.

Importação de Dados

Ficheiros de Texto (2)

- Ficheiros CSV (*comma-separated values*): os valores da linha são separados por vírgulas.

pesoalt.csv

Nome, Peso, Altura
Marco, 62.6, 1.65
Filipe, 55.4, 1.60
Valter, 70.2, 1.69
Nuno,, 1.72
João, 68.1, 1.73

```
dados <- read.csv("pesoalt.csv",  
                  header=TRUE)
```

dados

##		Nome	Peso	Altura
## 1		Marco	62.6	1.65
## 2		Filipe	55.4	1.60
## 3		Valter	70.2	1.69
## 4		Nuno	NA	1.72
## 5		João	68.1	1.73

Importação de Dados

Ficheiros de Texto (3)

- Em alguns países, onde a vírgula é usada como separador decimal, é comum usar o ponto-e-vírgula como separador.

pesoaltPT.csv

```
Nome; Peso; Altura
Marco; 62,6; 1,65
Filipe; 55,4; 1,60
Valter; 70,2; 1,69
Nuno;; 1,72
João; 68,1; 1,73
```

```
dados <- read.csv2("pesoaltPT.csv",
                    header=TRUE)
```

dados

```
##      Nome Peso  Altura
## 1  Marco 62.6   1.65
## 2 Filipe 55.4   1.60
## 3 Valter 70.2   1.69
## 4   Nuno  NA    1.72
## 5  João 68.1   1.73
```

Importação de Dados

Ficheiros de Texto (4)

- A função `read.table()` permite a importação de dados a partir de um qualquer formato de texto.

pesoalt.txt

Nome	Peso	Altura
Marco	62.6	1.65
Filipe	55.4	1.60
Valter	70.2	1.69
Nuno	???	1.72
João	68.1	1.73

```
dados <- read.table("pesoalt.txt",
                    header=TRUE, na.strings="??")
```

dados

```
##      Nome  Peso  Altura
## 1  Marco  62.6    1.65
## 2 Filipe  55.4    1.60
## 3 Valter  70.2    1.69
## 4   Nuno   NA     1.72
## 5  João  68.1    1.73
```

Importação de Dados

Ficheiros de Texto (5)

- ▶ Família de funções para importação de dados a partir de ficheiros: `read.table()`, `read.csv()`, `read.csv2()`, `read.delim()`. etc.
- ▶ Alguns parâmetros:
 - ▶ `sep`: indica o caracter separador das colunas;
 - ▶ `dec`: indica o separador decimal;
 - ▶ `header`: indica se a primeira linha contém o nome das colunas;
 - ▶ `na.strings`: indica o conjunto de valores de texto que deve ser interpretado como valores desconhecidos, i.e. NA.

Importação de Dados

Folhas de Cálculo

- ▶ Existem vários métodos para importar dados a partir de uma folha de cálculo:
 - ▶ através de um ficheiro CSV;
 - ▶ através do *clipboard* ou área de transferência;
 - ▶ através de funções de *packages* específicos.

Importação de Dados

Folhas de Cálculo (2)

- Podemos importar dados de uma folha de cálculo guardando o seu conteúdo num ficheiro de texto (p. ex. CSV)

pesoalt.xls

	A	B	C	D
1	Nome	Peso	Altura	
2	Marco	62.6	1.65	
3	Filipe	55.4	1.60	
4	Valter	70.2	1.69	
5	Nuno		1.72	
6	João	68.1	1.73	
7				
8				
9				



pesoalt.csv

```
Nome, Peso, Altura
Marco, 62.6, 1.65
Filipe, 55.4, 1.60
Valter, 70.2, 1.69
Nuno,, 1.72
João, 68.1, 1.73
```


- e depois carregando o conteúdo do ficheiro para um *data frame* no R, através de funções como `read.table`, `read.csv`, etc

```
dados <- read.csv("pesoalt.csv", header=TRUE)
```

Importação de Dados

Folhas de Cálculo (3)

- Podemos importar dados de uma folha de cálculo, seleccionando e copiando a área que pretendemos na folha de cálculo



	A	B	C	D
1	Nome	Peso	Altura	
2	Marco	62.6	1.65	
3	Filipe	55.4	1.60	
4	Valter	70.2	1.69	
5	Nuno		1.72	
6	João	68.1	1.73	
7				
8				
9				
10				
11				
12				
13				

- e depois usando a função `read.table()` sobre o “ficheiro temporário” `clipboard`.

```
dados <- read.table("clipboard",header=TRUE)
```

- Não é muito aconselhável porque o acesso ao `clipboard` pode variar com o sistema operativo.

Importação de Dados

Folhas de Cálculo (4)

- ▶ Podemos importar dados de uma folha de cálculo, usando um *package* com uma função específica para tal.
- ▶ Exemplos:
 - ▶ *package* gdata, função `read.xls()`

```
library(gdata)
dados <- read.xls("/Users/rpribeiro/Desktop/pesoalt.xls",
                  sheet=1)
```

- ▶ *package* readxl, função `read_excel()`

```
library(readxl)
dados <- read_excel("/Users/rpribeiro/Desktop/pesoalt.xls",
                    sheet=1)
```

Importação de Dados

Outras Fontes de Dados

- ▶ Bases de Dados
 - ▶ O R faz *interface* com os SGBD principais através de *packages* como DBI, RMySQL, ROracle, etc.
- ▶ Software Estatístico
 - ▶ O R importa dados a partir do SPSS, Stata, S-Plus, SAS, etc. através dos *packages* `foreign`, `Hmisc`.
- ▶ Vários outros formatos e software
 - ▶ Mais detalhes no manual [R Data Import/Export](#)'.

Manipulação de Dados

Informações Básicas

- ▶ Existem funções que permitem inspecionar o conteúdo de data frames, sem que para tal seja necessário mostrar todo data frame. Estas funções são especialmente úteis perante grandes conjuntos de dados.

```
dim(Pima.tr) # número de linhas e colunas

## [1] 200    8

str(Pima.tr) # obter descrição da estrutura

## 'data.frame': 200 obs. of  8 variables:
##  $ npreg: int  5 7 5 0 0 5 3 1 3 2 ...
##  $ glu  : int  86 195 77 165 107 97 83 193 142 128 ...
##  $ bp   : int  68 70 82 76 60 76 58 50 80 78 ...
##  $ skin : int  28 33 41 43 25 27 31 16 15 37 ...
##  $ bmi  : num  30.2 25.1 35.8 47.9 26.4 35.6 34.3 25.9 32.4 43.3 ...
##  $ ped  : num  0.364 0.163 0.156 0.259 0.133 ...
##  $ age  : int  24 55 35 26 23 52 25 24 63 31 ...
##  $ type : Factor w/ 2 levels "No","Yes": 1 2 1 1 1 2 1 1 1 2 ...
```

Manipulação de Dados

Informações Básicas (2)

```
head(Pima.tr) # primeiras linhas
```

```
##      npreg glu bp skin  bmi    ped age type
## 1         5  86 68   28 30.2 0.364  24   No
## 2         7 195 70   33 25.1 0.163  55   Yes
## 3         5   77 82   41 35.8 0.156  35   No
## 4         0 165 76   43 47.9 0.259  26   No
## 5         0 107 60   25 26.4 0.133  23   No
## 6         5   97 76   27 35.6 0.378  52   Yes
```

```
tail(Pima.tr) # últimas linhas
```

```
##      npreg glu bp skin  bmi    ped age type
## 195         1 140 74   26 24.1 0.828  23   No
## 196         2 141 58   34 25.4 0.699  24   No
## 197         7 129 68   49 38.5 0.439  43   Yes
## 198         0 106 70   37 39.4 0.605  22   No
## 199         1 118 58   36 33.3 0.261  23   No
## 200         8 155 62   26 34.0 0.543  46   Yes
```

Manipulação de Dados com `dplyr`

- ▶ O package `dplyr` oferece funcionalidades que permitem manipular dados em R, de forma fácil e também eficiente.
- ▶ Permite lidar com várias fontes de dados (data frames, bases de dados, etc.)
- ▶ Tem implementadas as operações mais básicas de manipulação de dados.

Manipulação de Dados com dplyr

Formato dos Dados

- ▶ Os dados são guardados em data frame tables, uma espécie de data frames.
- ▶ A principal vantagem é na impressão

```
library(dplyr)
p <- tbl_df(Pima.tr)
p

## # A tibble: 200 × 8
##   npreg   glu   bp  skin   bmi   ped   age  type
## *   <int> <int> <int> <int> <dbl> <dbl> <int> <fctr>
## 1     5    86   68   28  30.2  0.364   24    No
## 2     7   195   70   33  25.1  0.163   55    Yes
## 3     5    77   82   41  35.8  0.156   35    No
## 4     0   165   76   43  47.9  0.259   26    No
## 5     0   107   60   25  26.4  0.133   23    No
## 6     5    97   76   27  35.6  0.378   52    Yes
## 7     3    83   58   31  34.3  0.336   25    No
## 8     1   193   50   16  25.9  0.655   24    No
## 9     3   142   80   15  32.4  0.200   63    No
## 10    2   128   78   37  43.3  1.224   31    Yes
## # ... with 190 more rows
```

Manipulação de Dados com `dplyr`

Operações Básicas

- ▶ `filter` - mostrar um subconjunto de linhas
- ▶ `select` - mostrar um subconjunto de colunas
- ▶ `arrange` - reordenar linhas
- ▶ `mutate` - adicionar novas colunas
- ▶ `summarise` - sumarizar valores de uma coluna

Manipulação de Dados com dplyr

Operações Básicas: Algumas Regras

```
dados2 <- <operacao>(dados1,...)
```

- ▶ O primeiro argumento (dados1) é um data frame table.
- ▶ Os restantes argumentos (...) descrevem o que fazer com os dados.
- ▶ O objeto retornado (dados2) é do mesmo tipo do primeiro argumento (com exceção da operação summarise).
- ▶ O objeto no primeiro argumento nunca é alterado.

Manipulação de Dados com dplyr

Operações Básicas: *filter*

```
dados2 <- filter(dados1, cond1, cond2, ...)
```

- ▶ Retorna as linhas que satisfazem TODAS as condições indicadas.

```
filter(p, npreg > 4, age < 30)
```

```
## # A tibble: 10 × 8
##   npreg  glu   bp  skin  bmi  ped  age  type
##   <int> <int> <int> <int> <dbl> <dbl> <int> <fctr>
## 1     5    86   68   28  30.2  0.364   24   No
## 2     5   123   74   40  34.1  0.269   28   No
## 3     6   109   60   27  25.0  0.206   27   No
## 4     5   139   80   35  31.6  0.361   25   Yes
## 5     6   134   70   23  35.4  0.542   29   Yes
## 6     5   158   84   41  39.4  0.395   29   Yes
## 7     6   111   64   39  34.2  0.260   24   No
## 8     6   154   78   41  46.1  0.571   27   No
## 9     5   139   64   35  28.6  0.411   26   No
## 10    5   105   72   29  36.9  0.159   28   No
```

```
filter(p, npreg > 6 | age > 50)
```

```
## # A tibble: 49 × 8
##   npreg  glu   bp  skin  bmi  ped  age  type
##   <int> <int> <int> <int> <dbl> <dbl> <int> <fctr>
## 1     7   195   70   33  25.1  0.163   55   Yes
## 2     5    97   76   27  35.6  0.378   52   Yes
## 3     3   142   80   15  32.4  0.200   63   No
## 4     9   154   78   30  30.9  0.164   45   No
## 5     1   189   60   23  30.1  0.398   59   Yes
## 6    12    92   62    7  27.6  0.926   44   Yes
## 7    11   143   94   33  36.6  0.254   51   Yes
## 8     9   164   84   21  30.8  0.831   32   Yes
## 9    13   145   82   19  22.2  0.245   57   No
## 10    8   176   90   34  33.7  0.467   58   Yes
## # ... with 39 more rows
```

Manipulação de Dados com dplyr

Operações Básicas: *arrange*

```
dados2 <- arrange(dados1, col1, col2, ...)
```

- Reordena as linhas pela `col1`, depois pela `col2`, etc.

```
arrange(p,age)
```

```
## # A tibble: 200 × 8
##   npreg   glu   bp  skin   bmi   ped   age   type
##   <int> <int> <int> <int> <dbl> <dbl> <int> <fctr>
## 1      4    99    76    15  23.2  0.223    21    No
## 2      1   109    60     8  25.4  0.947    21    No
## 3      0   139    62    17  22.1  0.207    21    No
## 4      0   101    64    17  21.0  0.252    21    No
## 5      1    99    58    10  25.4  0.551    21    No
## 6      1    97    64    19  18.2  0.299    21    No
## 7      1   114    66    36  38.1  0.289    21    No
## 8      1    96    64    27  33.2  0.289    21    No
## 9      2   100    64    23  29.7  0.368    21    No
## 10     2   115    64    22  30.8  0.421    21    No
## # ... with 190 more rows
```

```
arrange(p,desc(npreg),age)
```

```
## # A tibble: 200 × 8
##   npreg   glu   bp  skin   bmi   ped   age   type
##   <int> <int> <int> <int> <dbl> <dbl> <int> <fctr>
## 1     14   175    62    30  33.6  0.212    38    Yes
## 2     14   100    78    25  36.6  0.412    46    Yes
## 3     13   145    82    19  22.2  0.245    57    No
## 4     12   151    70    40  41.8  0.742    38    Yes
## 5     12   140    85    33  37.4  0.244    41    No
## 6     12    92    62     7  27.6  0.926    44    Yes
## 7     12    88    74    40  35.3  0.378    48    No
## 8     12   140    82    43  39.2  0.528    58    Yes
## 9     12   121    78    17  26.5  0.259    62    No
## 10    11   143    94    33  36.6  0.254    51    Yes
## # ... with 190 more rows
```

Manipulação de Dados com dplyr

Operações Básicas: *select*

```
dados2 <- select(dados1, col1, col2, ...)
```

- Mostra os valores das colunas col1, col2, etc.

```
select(p,npreg,age)
```

```
## # A tibble: 200 × 2
##   npreg  age
## *   <int> <int>
## 1     5   24
## 2     7   55
## 3     5   35
## 4     0   26
## 5     0   23
## 6     5   52
## 7     3   25
## 8     1   24
## 9     3   63
## 10    2   31
## # ... with 190 more rows
```

```
select(p,bmi:type)
```

```
## # A tibble: 200 × 4
##   bmi  ped  age  type
## *   <dbl> <dbl> <int> <fctr>
## 1  30.2  0.364   24    No
## 2  25.1  0.163   55   Yes
## 3  35.8  0.156   35    No
## 4  47.9  0.259   26    No
## 5  26.4  0.133   23    No
## 6  35.6  0.378   52   Yes
## 7  34.3  0.336   25    No
## 8  25.9  0.655   24    No
## 9  32.4  0.200   63    No
## 10 43.3  1.224   31   Yes
## # ... with 190 more rows
```

```
select(p,starts_with("b"))
```

```
## # A tibble: 200 × 2
##   bp  bmi
## *   <int> <dbl>
## 1    68  30.2
## 2    70  25.1
## 3    82  35.8
## 4    76  47.9
## 5    60  26.4
## 6    76  35.6
## 7    58  34.3
## 8    50  25.9
## 9    80  32.4
## 10   78  43.3
## # ... with 190 more rows
```

Manipulação de Dados com dplyr

Operações Básicas: *mutate*

```
dados2 <- mutate(dados1, novacol1, novacol2, ...)
```

- Adiciona as colunas novacol1, novacol2, etc.. Não altera o conjunto de dados original dados1

```
mutate(p,xpto=npreg*bmi/age)
```

```
## Source: local data frame [200 x 9]
##
##   npreg glu bp skin  bmi  ped age type  xpto
## 1     5  86 68  28 30.2 0.364 24  No 6.291667
## 2     7 195 70  33 25.1 0.163 55 Yes 3.194545
## 3     5  77 82  41 35.8 0.156 35  No 5.114286
## 4     0 165 76  43 47.9 0.259 26  No 0.000000
## 5     0 107 60  25 26.4 0.133 23  No 0.000000
## 6     5  97 76  27 35.6 0.378 52 Yes 3.423077
## 7     3  83 58  31 34.3 0.336 25  No 4.116000
## 8     1 193 50  16 25.9 0.655 24  No 1.079167
## 9     3 142 80  15 32.4 0.200 63  No 1.542857
## 10    2 128 78  37 43.3 1.224 31 Yes 2.793548
## .. ... ..
```

Manipulação de Dados com dplyr

Composição de Operações Básicas

- Podemos usar a composição de funções para encadear um conjunto de operações.

```
select(filter(p, npreg > 4, age < 30), npreg, age, type)
```

```
## Source: local data frame [10 x 3]
```

```
##
```

```
##      npreg age type
```

```
## 1         5  24   No
```

```
## 2         5  28   No
```

```
## 3         6  27   No
```

```
## 4         5  25  Yes
```

```
## 5         6  29  Yes
```

```
## 6         5  29  Yes
```

```
## 7         6  24   No
```

```
## 8         6  27   No
```

```
## 9         5  26   No
```

```
## 10        5  28   No
```

Manipulação de Dados com dplyr

Composição de Operações Básicas (2)

- Contudo, a composição de funções pode tornar-se complexa

```
arrange(  
  select(  
    filter(  
      mutate(p,xpto=npreg*bmi/age),  
      xpto > 1.5,npreg > 4,age < 30),  
    npreg,age,type),  
  desc(age)  
)
```

```
## Source: local data frame [10 x 3]
```

```
##
```

```
##   npreg age type
```

```
## 1     6  29  Yes
```

```
## 2     5  29  Yes
```

```
## 3     5  28   No
```

```
## 4     5  28   No
```

```
## 5     6  27   No
```

```
## 6     6  27   No
```

```
## 7     5  26   No
```

```
## 8     5  25  Yes
```

```
## 9     5  24   No
```

```
## 10    6  24   No
```

Manipulação de Dados com dplyr

Composição de Operações Básicas (3)

- ▶ Em alternativa, podemos usar o operador de encadeamento `%>%`
- ▶ O conjunto de dados que resulta de cada operação vai sendo passado, implicitamente, como 1º argumento às operações seguintes.

```
mutate(p,xpto=npreg*bmi/age) %>% filter(xpto > 1.5, npreg > 4, age < 30) %>%  
  select(npreg,age,type) %>% arrange(desc(age))
```

```
## Source: local data frame [10 x 3]
```

```
##
```

```
##   npreg age type
```

```
## 1     6  29  Yes
```

```
## 2     5  29  Yes
```

```
## 3     5  28   No
```

```
## 4     5  28   No
```

```
## 5     6  27   No
```

```
## 6     6  27   No
```

```
## 7     5  26   No
```

```
## 8     5  25  Yes
```

```
## 9     5  24   No
```

```
## 10    6  24   No
```

Manipulação de Dados com dplyr

Operações Básicas: *summarise*

```
dados2 <- summarise(dados1, sumF1, sumF2, ...)
```

- Sumaria as linhas de dados1 usando as funções sumF1, sumF2, ...

```
summarise(p,varBmi=var(bmi),avgAge = mean(age),nAge=n_distinct(age))
```

```
## Source: local data frame [1 x 3]
```

```
##
```

```
##   varBmi avgAge nAge
```

```
## 1 37.5795 32.11 39
```

Manipulação de Dados com dplyr

Operações Básicas: *group_by*

```
dados2 <- group_by(dados1, crit1, crit2, ...)
```

- ▶ Cria grupos de linhas de dados de acordo com os critérios.
- ▶ Sobre esse grupos podem depois ser aplicadas funções.

```
group_by(p,type)
```

```
## Source: local data frame [200 x 8]
## Groups: type
##
##   npreg glu bp skin  bmi  ped age type
## 1     5  86 68  28 30.2 0.364 24  No
## 2     7 195 70  33 25.1 0.163 55  Yes
## 3     5  77 82  41 35.8 0.156 35  No
## 4     0 165 76  43 47.9 0.259 26  No
## 5     0 107 60  25 26.4 0.133 23  No
## 6     5  97 76  27 35.6 0.378 52  Yes
## 7     3  83 58  31 34.3 0.336 25  No
## 8     1 193 50  16 25.9 0.655 24  No
## 9     3 142 80  15 32.4 0.200 63  No
## 10    2 128 78  37 43.3 1.224 31  Yes
## .. ... ..
```

```
group_by(p,type) %>%
  summarise(count = n(),
            avg_age = mean(age),
            avg_npreg = mean(npreg))
```

```
## Source: local data frame [2 x 4]
##
##   type count  avg_age avg_npreg
## 1  No    132 29.23485  2.916667
## 2  Yes     68 37.69118  4.838235
```

Manipulação de Dados com dplyr

Operações Básicas

- ▶ Mais detalhes sobre estas outras operações de manipulação de dados podem ser consultados em:

[Data Wrangling with dplyr and tidyr.](#)