

MAC 113 — Introdução à Ciência da Computação

Aula 25

Nelson Lago

1º/2025



Previously on MAC113...

Comandos básicos com vectors e lists

- `vec <- 1:10`
- `vec <- seq_len(4)`
- `vec <- rep(3.14, 4)`
- `vec <- c("a", "b", "c")`
- `lista <- list(a=1, b=2, c=3)`
- `length(blah)` (list ou vector)
- `tudo_junto <- c(blah, bleh)`
(lists ou vectors)
- `vec[X]`
- `lista[[X]]` (numérico)
- `blah[X:Y]`
(numérico – lists ou vectors)
- `lista[[X]]` (character)
- `lista$X`
(character, atalho sem aspas)
- `for (item in blah)`
(list ou vector)
- `names(lista)`
 - ▶ `for (nome in names(lista))`
- `unlist(lista)`
- `vec[X] <- valor` (atribui)
- `vec <- append(vec, valor)`
(acrescenta)
- `lista$nome <- valor`
(atribui ou acrescenta)

Tabelas

Paciente	Colesterol (mg/dL)	Idade	Quarto	SUS
Fulano de Tal	164	49	132-A	S
Ciclano de Tal	227	83	231-B	N
Média/Total	195,6	66	–	1

- Por que usamos tabelas?
- Provavelmente, várias razões 🤪
- Uma delas é que se trata de uma **visualização dupla**
- Podemos olhar cada **linha** ou cada **coluna**

Tabelas

- **Em tabelas desse tipo**

- ▶ Cada linha corresponde a uma abstração (“pessoa”, “produto” etc.)
- ▶ Cada coluna corresponde a uma coleção de valores de um mesmo tipo (“preço”, “colesterol”, “idade” etc.)

- **Podemos armazenar cada linha como uma list**

- ▶ Mas processar as colunas (por exemplo, para calcular a média) é trabalhoso

- **Podemos armazenar cada coluna como um vector e usar os índices para identificar as linhas**

- ▶ Mas já vimos antes que isso é um tanto trabalhoso também

- **Podemos usar uma list em que cada elemento é um vector correspondente a uma coluna**

- ▶ Mas isso é apenas uma variação da ideia anterior



Precisamos de algo novo!

Algo que se assemelhe a uma **tabela**

Dataframes

(na verdade, **tibbles**)

Dataframes

- Dataframes são bastante similares a lists
- Cada item é um vector que representa uma coluna

```
library(tibble)
#df <- data.frame(nome=c("Zé", "Fê", "Má", "Lú"), ID=c(1,2,3,4), nota=c(7, 8.5, 8.3, 9.1))
df <- tibble(nome=c("Zé", "Fê", "Má", "Lú"), ID=c(1,2,3,4), nota=c(7, 8.5, 8.3, 9.1))
cat("Alunos:", df$nome, "\n")
cat("Média da turma:", mean(df$nota), "\n")
cat("Lista de chamada:\n")
cat(paste(df$nome, " (", df$ID, ") _____", sep=""), sep="\n")
```

Alunos: Zé Fê Má Lú

Média da turma: 8.225

Lista de chamada:

Zé (1) _____

Fê (2) _____

Má (3) _____

Lú (4) _____

Recortes com dataframes

- A maneira mais razoável de nos referirmos a elementos em uma tabela é através de suas **coordenadas**

1	2	3	4
5	6	7	8
9	10	11	12

- $tabela_{l,c}$

- $tabela_{1-2, 2-3}$

2	3
6	7

Dataframes

```
library(tibble)
#df <- data.frame(nome=c("Zé", "Fê", "Má", "Lú"), ID=c(1,2,3,4), nota=c(7, 8.5, 8.3, 9.1))
df <- tibble(nome=c("Zé", "Fê", "Má", "Lú"), ID=c(1,2,3,4), nota=c(7, 8.5, 8.3, 9.1))
cat("Boletim de notas:\n")
for (i in seq_len(nrow(df))) {
  line <- df[i,]
  cat(unlist(line[c("nome", "nota")] ), "\n")
}
```

Boletim de notas:

Zé 7

Fê 8.5

Má 8.3

Lú 9.1

Dataframes

- **Em geral, as operações vetoriais que fazemos em dataframes/tibbles processam as colunas**
 - ▶ Como cada coluna é um vector, sabemos que os elementos são todos do mesmo tipo
 - ▶ Em geral, coisas como `max()`, `mean()`, `sum()` etc., fazem sentido com as colunas
- **Para processar as linhas, podemos extrair uma linha específica por sua coordenada:**
 - ▶ `df[3,]`
- **ou, para processar todas, fazer um laço:**
 - ▶ `for (i in seq_len(nrow(df))) { df[i,] }`
- **ou usar `paste()`**
- ...

Dataframes

Dataframes/tibbles: Como vivem? Onde moram? De que se alimentam?

- Não tem muita graça digitar os dados de um dataframe/tibble como parte do programa
- O mais razoável é carregar de um **arquivo**
- Dataframes são tabelas → o arquivo deve representar uma tabela
- O formato mais comumente usado é o **CSV** (comma-separated values)

Nome	matemática	português	física	história
Alan Turing	9.7	1.4	9.2	8.7
Ada Lovelace	9.8	1.2	10.0	9.2

Dataframes

```
Nome,matemática,português,física,história
Alan Turing,9.7,1.4,9.2,8.7
Ada Lovelace,9.8,1.2,10.0,9.2
```

```
Nome      ,matemática,português,física,história
Alan Turing  ,9.7      ,1.4      ,9.2      ,8.7
Ada Lovelace ,9.8      ,1.2      ,10.0     ,9.2
```

- CSV: “Comma” pode ser qualquer coisa (espaços, tabs...)

```
Nome;matemática;português;física;história
Alan Turing;9,7;1,4;9,2;8,7
Ada Lovelace;9,8;1,2;10,0;9,2
```

Dataframes

- E como ler um arquivo desses?

```
endereço <- 'http://www.ime.usp.br/~lago/dadinhos/renda_vs_inflacao.csv'
#df <- read.table(endereço, sep=",", header=TRUE) # dataframe
library(readr)
df <- read_delim(endereço, delim=",", col_types = "idd")
names(df)[2] <- "PIBpc"
print(head(df))
```


```
# A tibble: 6 × 3
  ano  PIBpc  IPCA
<int> <dbl> <dbl>
1  2000  6913.    7
2  2001  7467    6.8
3  2002  8341.    8.4
4  2003  9507.   14.7
5  2004 10706    6.6
6  2005 11734.    6.9
```

Dataframes

```
endereço <- 'http://www.ime.usp.br/~lago/dadinhos/renda_vs_inflacao.csv'
#df <- read.table(endereço, sep=";", header=TRUE) # dataframe
library(readr)
df <- read_delim(endereço, delim=";", col_types = "idd")
names(df)[2] <- "PIBpc"
p <- ggplot(df, aes(x=ano, y=PIBpc)) +
  geom_line() +
  geom_point() +
  labs(title="PIB per capita anual brasileiro")
print(p)
```

Dataframes

PIB per capita anual brasileiro



And now for something a little bit different

Recortes com filtros

- Dado um dataframe **df** (ou um vector/lista), podemos fazer um “recorte” usando coordenadas: **df[linhas,colunas]**
 - ▶ linhas e colunas podem ser valores únicos ou vectors
- Também podemos usar um vector do tipo **LOGICAL**

```
vec <- 1:5
cat(vec[c(TRUE, FALSE, FALSE, TRUE, FALSE)], "\n")
1 4
grandes <- vec > 3
cat(grandes, "\n")
FALSE FALSE FALSE TRUE TRUE
cat(vec[grandes], "\n")
4 5
cat(vec[vec > 3], "\n")
4 5
```

Recortes com filtros

```
library(tibble)
df <- tibble(nome=c("Fulano", "Ciclano", "Beltrano"), idade=c(17, 25, 19))
cat("Idade do Fulano:", unlist(df[df$nome == "Fulano", "idade"]), "\n")
```

Idade do Fulano: 17

```
library(tibble)
df <- tibble(nome=c("Fulano", "Ciclano", "Beltrano"), idade=c(17, 25, 19))
cat("Maiores de idade:", unlist(df[df$idade>=18,]), "\n")
maiores <- df[df$idade>=18,]
cat("Maiores de idade:", paste(maiores$nome, ":", maiores$idade, sep=""), sep="\n")
```

Maiores de idade: Ciclano Beltrano 25 19

Maiores de idade:

Ciclano: 25

Beltrano: 19

Exercício – dados de filmes

<http://www.ime.usp.br/~lago/dadinhos/filmes.csv>

nome	diretor	ano	nota	infantil	país
<chr>	<chr>	<int>	<dbl>	<chr>	<chr>
A hora mágica	Guilherme de A Prado	1999	6.7	N	Brasil
Central do Brasil	Walter Salles	1998	8	N	Brasil
Os incríveis	Brad Bird	2004	8	S	EUA
Na roda da fortuna	Joel Coen, Ethan Coen	1994	7.2	N	EUA
O fantasma do paraíso	Brian de Palma	1974	7.3	N	EUA
Asas do desejo	Wim Wenders	1987	7.9	N	Alemanha Ocidental
Peixe grande	Tim Burton	2003	8	N	EUA

Exercício – dados de filmes

- Dada a lista de filmes em

<http://www.ime.usp.br/~lago/dadinhos/filmes.csv>

- ▶ Quantos filmes há na lista? antigo e o ano de lançamento
- ▶ Qual é a avaliação média mais novo da lista?
- ▶ Qual o ano de lançamento mais de lançamento?

```
library(readr)
main <- function() {
  arq <- 'http://www.ime.usp.br/~lago/dadinhos/filmes.csv'
  filmes <- read_delim(arq, delim=";", col_types = "ccidcc")
  cat("Há", nrow(filmes), "filmes na lista\n")
  cat("A avaliação média dos filmes é", mean(filmes$nota), "\n")
  cat("O filme mais antigo é de", min(filmes$ano),
      "e o filme mais novo é de", max(filmes$ano), "\n")
  cat("A mediana do ano de lançamento dos filmes é", median(filmes$ano), "\n")
}
main()
```

Exercício – dados de filmes

- Dada a lista de filmes em <http://www.ime.usp.br/~lago/dadinhos/filmes.csv>
 - ▶ Quantos filmes foram lançados no séc. XXI?

```
library(readr)
main <- function() {
  arq <- 'http://www.ime.usp.br/~lago/dadinhos/filmes.csv'
  filmes <- read_delim(arq, delim=";", col_types = "ccidcc")
  cat(nrow(filmes[filmes$ano > 2000,]), "filmes foram lançados no séc. XXI\n")
}
main()
```

Exercício – dados de filmes

- Dada a lista de filmes em <http://www.ime.usp.br/~lago/dadinhos/filmes.csv>
 - ▶ Quantos filmes foram lançados entre 1993 e 2007?

```
library(readr)
main <- function() {
  arq <- 'http://www.ime.usp.br/~lago/dadinhos/filmes.csv'
  filmes <- read_delim(arq, delim=";", col_types = "ccidcc")
  cat(nrow(filmes[filmes$ano >= 1993 & filmes$ano <= 2007,]),
      "filmes foram lançados entre 1993 e 2007\n")
}
main()
```

Exercício – dados de filmes

- Dada a lista de filmes em <http://www.ime.usp.br/~lago/dadinhos/filmes.csv>
 - ▶ Quais são os filmes infantis que há na lista?

```
library(readr)
main <- function() {
  arq <- 'http://www.ime.usp.br/~lago/dadinhos/filmes.csv'
  filmes <- read_delim(arq, delim=";", col_types = "ccidcc")
  print(filmes[filmes$infantil == "S",])
}
main()
```

mas pra que manter a coluna “infantil”?

Exercício – dados de filmes

- Dada a lista de filmes em <http://www.ime.usp.br/~lago/dadinhos/filmes.csv>
 - ▶ Quais são os filmes infantis que há na lista?

```
library(readr)
main <- function() {
  arq <- 'http://www.ime.usp.br/~lago/dadinhos/filmes.csv'
  filmes <- read_delim(arq, delim=";", col_types = "ccidcc")
  print(filmes[filmes$infantil == "S", names(filmes) != "infantil"])
}
main()
```

Intermezzo – o operador `%in%`

- Como saber se existe um elemento dentro de um vector?
- `if (valor %in% vector) { ... }`

Exercício – dados de filmes

- Dada a lista de filmes em <http://www.ime.usp.br/~lago/dadinhos/filmes.csv>
 - ▶ Quais são os filmes infantis que há na lista?

```
library(readr)
main <- function() {
  arq <- 'http://www.ime.usp.br/~lago/dadinhos/filmes.csv'
  filmes <- read_delim(arq, delim=";", col_types = "ccidcc")
  filmes$infantil <- filmes$infantil == "S"
  print(filmes[filmes$infantil, ! names(filmes) %in% c("infantil", "país")])
}
main()
```

Exercício – dados de filmes

- Dada a lista de filmes em <http://www.ime.usp.br/~lago/dadinhos/filmes.csv>
 - ▶ Quais e quantos países diferentes aparecem na lista?

```
library(readr)
main <- function() {
  arq <- 'http://www.ime.usp.br/~lago/dadinhos/filmes.csv'
  filmes <- read_delim(arq, delim=";", col_types = "ccidcc")
  cat(unique(filmes$país), sep="\n")
  cat(length(unique(filmes$país)), "\n")
}
main()
```