Introdução à linguagem R

Departamento de Estatística
Instituto de Matemática e Estatística
Universidade Federal da Bahia

Durante o curso

- Usaremos nas aulas: posit.cloud.
- Recomendamos instalar e usar `R` com versão pelo menos `4.1`: cran.r-project.org.
- usaremos o *framework* `tidyverse`:
  - Instalação: `install.packages("tidyverse")`

Na sua casa

- **IDE** recomendadas: *RStudio* e *VSCode*.
  - Caso você queira usar o *VSCode*, instale a extensão da linguagem `R`: `REditorSupport`.
- Outras linguagens interessantes: `python` e `julia`.
  - `python`: linguagem interpretada de próposito geral, contemporânea do `R`, simples e fácil de aprender.
  - `julia`: linguagem interpretada para análise de dados, lançada em 2012, promete simplicidade e velocidade.

A linguagem R:

uma introdução

Departamento de Estatística
IME - UFBA

O precursor do R: S.

- R é uma linguagem derivada do S.
- S foi desenvolvido em `fortran` por **John Chambers** em *1976* no **Bell Labs**.
- S foi desenvolvido para ser um ambiente de análise estatística.
- Filosofia do S: permitir que usuários possam analisar dados usando estatística com pouco conhecimento de programação.

História do R

- Em *1991*, **Ross Ihaka** e **Robert Gentleman** criaram o R na **Nova Zelândia**.
- Em *1996*, **Ross** e **Robert** liberam o R sob a licença "GNU General License", o que tornou o R um software livre.
- Em *1997*, **The Core Group** é criado para melhorar e controlar o código fonte do R.

Porque usar R

- Constante melhoramento e atualização.
- Portabilidade (roda em praticamente todos os sistemas operacionais).
- Grande comunidade de desenvolvedores que adicionam novas capacidades ao R através de pacotes.
- Gráficos de maneira relativamente simples.
- Interatividade.
- Um grande comunidade de usuários (especialmente útil para resolução de problemas).

Onde estudar fora de aula?

Livros

Recomendo principalmente o livro R for Data Science.

- **Nível Iniciante:** R Tutorial na W3Schools.
- **Nível Iniciante:** Hands-On Programming with R.
- **Nível Iniciante:** R for Data Science.
- **Nível Intermediário:** Advanced R.

Livros em português

- **Nível *cheguei agora aqui*:** zen do R.
- **Nível Avançado:** Advanced R.
- **Nível Iniciante:** material.curso-r.com.
- **Nível Iniciante:** ecoR.
- **Nível Iniciante:** analises-ecologicas.com.

Plataformas de ensino on-line

- **Datacamp:** datacamp.com
- **Dataquest:** dataquest.io

O que você pode fazer quando estiver em apuros?

- consultar a documentação do R:

```
help(mean)
?mean
```

- Peça ajuda a um programador mais experiente.

```
sqrt("Gilberto")
```

- Pesquise por `Como resolver o erro: Error in sqrt("Gilberto"): non-numeric argument to mathematical function`, nas seguintes plataformas:
  - Consulte o erro no chatgpt.
  - Consulte o erro pt.stackoverflow.com.
  - Consulte Rstudio community.
  - Use ferramentas de busca como o google e duckduckgo.com.

Soma

```
1 + 1
```

```
[1] 2
```

Substração

```
2 - 1
```

```
[1] 1
```

Divisão

```
3 / 2
```

```
[1] 1.5
```

Potenciação

```
2^3
```

```
[1] 8
```

Exercício

Qual o resultado das seguintes operações?

1. `5.32 + 7.99`
2. `5.55 - 10`
3. `3.33 * 5.12`
4. `1 / 4.55`
5. `5^1.23`

Função: é uma ação e tem os seguinte componentes na ordem:

- *nome da função*
- *parênteses*
- *argumentos posicionais*
- *argumentos nomeados*

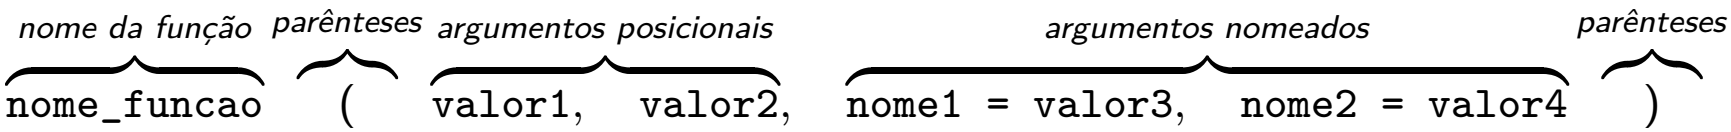

example:

```
read_xlsx('data/raw/casas.xlsx', sheet=1)
```

Funções na linguagem R
Exercício

- Obtenha ajuda para `mean` usando a função `help`.
- Calcule o logaritmo de 10 na base 3 usando a função `log`.
- Leia o conjunto de dados `amostra_enem_salvador.xlsx` usando a função `read_xlsx` do pacote `readxl`.

Estrutura de dados no R

- **Tipo de dados:** caracter (`character`), número real (`double`), número inteiro (`integer`), número complexo (`complex`) e lógico (`logical`).
- **Estrutura de dados:** atomic `vector` (a estrutura de dados mais básicA no R), `matrix`, `array`, `list` e `data.frame` (`tibble` no `tidyverse`).
- **Estrutura de dados Homogênea:** `vector`, `matrix` e `array`.
- **Estrutura de dados Heterôgenea:** `list` e `data.frame` (`tibble` no `tidyverse`).

Número inteiro

```
class(1L)
```

```
[1] "integer"
```

Número real

```
class(1.2)
```

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

Número complexo

```
class(1 + 1i)
```

```
[1] "complex"
```

Número lógico ou valor booleano

```
class(TRUE)
```

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

Caracter ou *string*

```
class("Gilberto")
```

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

Vetor

- Agrupamento de valores de mesmo tipo em um único objeto.
- Criação de vetor:
  - `c(...)`;
  - `vector('<tipo de dados>', <comprimento do vetor>)`;
  - `seq(from = a, to = b, by = c)`;
  - `seq_along(<vetor>)` - vetor de números inteiros com o mesmo trabalho de `<vetor>`;
  - `seq_len(<número inteiro>)` - vetor de números inteiros com o tamanho `<número inteiro>`;
  - `<número inicial>:<número final>` - sequência de números inteiros entre `<número inicial>` e `<número final>`
- Podemos checar o `tipo de dados` de um vetor com a função `class`.

Vetor de caracteres

```
nomes  <- c("Gilberto", "Sassi")
class(nomes)
```

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

```
nomes
```

```
[1] "Gilberto" "Sassi"
```

```
texto_vazio <- vector("character", 3)
class(texto_vazio)
```

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

```
texto_vazio
```

```
[1] "" "" ""
```

Vetor de números reais

```
vetor_real  <- c(0.2, 1.35)
class(vetor_real)
```

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

```
vetor_real
```

```
[1] 0.20 1.35
```

```
vetor_real <- vector("double", 3)
vetor_real
```

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

```
vetor_real <- seq(from = 1, to = 3.5, by = 0.5)
vetor_real
```

```
[1] 1.0 1.5 2.0 2.5 3.0 3.5
```

Vetor de números inteiros

```
vetor_inteiro  <- c(1L, 2L)
class(vetor_inteiro)
```

```
[1] "integer"
```

```
vetor_inteiro
```

```
[1] 1 2
```

```
vetor_inteiro <- vector("integer", 3)
vetor_inteiro
```

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

```
vetor_inteiro <- 1:4
vetor_inteiro
```

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

```r
vetor_real  <- seq_along(nomes)
class(vetor_real)
```

```
[1] "integer"
```

```r
vetor_real
```

```
[1] 1 2
```

```r
vetor_real <- seq_len(5)
class(vetor_real)
```

```
[1] "integer"
```

```r
vetor_real
```

```
[1] 1 2 3 4 5
```

Vetor lógico

```
vetor_logico  <- c(TRUE, FALSE)
class(vetor_logico)
```

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

```
vetor_logico
```

```
[1]  TRUE FALSE
```

```
vetor_logico <- vector("logical", 3)
vetor_logico
```

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

Estrutura de dados homogênea
Exercício

Crie os seguintes vetores:

1. $(0,1 \quad 0,2 \quad 0,3 \quad 0,4 \quad 0,5)$
2. $(TRUE \quad TRUE \quad FALSE)$
3. $(\text{"}Marx\text{"} \quad \text{"}Engels\text{"} \quad \text{"}Lênin\text{"})$
4. $(1 \quad 2 \quad 3)$

Departamento de Estatística
IME - UFBA

Operações com vetores números (`double`, `integer` e `complex`).

- Operações básicas (operação, substração, multiplicação e divisão) realizada em cada elemento do vetor.
- *Slicing*: extrair parte de um vetor (não precisa ser vetor numérico).

Slicing

```
vetor <- c("a", "b", "c", "d", "e", "f", "g", "h", "i")
# selecionado todos os elementos entre o primeiro e o quinta
vetor[1:5]
```

```
[1] "a" "b" "c" "d" "e"
```

Adição (vetores números)

```
vetor_1 <- 1:5
vetor_2 <- 6:10
vetor_1 + vetor_2
```

```
[1]  7  9 11 13 15
```

Substração (vetores numéricos)

```
vetor_1 <- 1:5
vetor_2 <- 6:10
vetor_2 - vetor_1
```

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

Multiplicação (vetores numéricos)

```
vetor_1 <- 1:5
vetor_2 <- 6:10
vetor_2 * vetor_1
```

```
[1]  6 14 24 36 50
```

Divisão (vetores numéricos)

```
vetor_1 <- 1:5
vetor_2 <- 6:10
vetor_2 / vetor_1
```

```
[1] 6.000000 3.500000 2.666667 2.250000 2.000000
```

Estrutura de dados homogênea
Exercício

Realize as seguintes operações envolvendo vetores:

1. $\begin{pmatrix}1 & 2 & 3\end{pmatrix} + \begin{pmatrix}0,1 & 0,05 & 0,33\end{pmatrix}$
2. $\begin{pmatrix}1 & 2 & 3\end{pmatrix} - \begin{pmatrix}0,1 & 0,05 & 0,33\end{pmatrix}$
3. $\begin{pmatrix}1 & 2 & 3\end{pmatrix} * \begin{pmatrix}0,1 & 0,05 & 0,33\end{pmatrix}$
4. $\begin{pmatrix}1 & 2 & 3\end{pmatrix} / \begin{pmatrix}0,1 & 0,05 & 0,33\end{pmatrix}$

Fatores (`factor`)

Podemos fixar o conjunto de valores possíveis de uma variável qualitativa (e especificar uma ordem implícita) usando `factor`.

Principais vantagens:

- Evita os erros de digitação.
- Introduz uma ordenação que pode ser útil para construir gráficos e tabelas.
- Necessário para funções de modelagem estatística (que não veremos neste curso).

Vamos usar o pacote `forcats`.

Função `fct` do pacote `forcats`: transforma uma variável qualitativa (`chr`) em fator (`fct`).

- `x`: primeiro vetor de texto;
- `levels`: valores possíveis da variável qualitativa, onde a ordem de inputação é a ordem implícita. Se não fornecida, `fct` usará a ordem de aparição.

Vamos transformar a variável especie em fator.

```
dados_iris <- read_xlsx("dados/brutos/iris.xlsx")

niveis <- c("setosa", "versicolor", "virginica")
dados_iris <- mutate(
  dados_iris,
  especies = fct(especies, levels = niveis)
)
glimpse(dados_iris)
```

```
Rows: 150
Columns: 5
$ comprimento_sepala <dbl> 5.1, 4.9, 4.7, 4.6, 5.0, 5.4, 4.6, 5.
$ largura_sepala     <dbl> 3.5, 3.0, 3.2, 3.1, 3.6, 3.9, 3.4, 3.
$ comprimento_petala <dbl> 1.4, 1.4, 1.3, 1.5, 1.4, 1.7, 1.4, 1.
$ largura_petala     <dbl> 0.2, 0.2, 0.2, 0.2, 0.2, 0.4, 0.3, 0.
$ especies           <fct> setosa, setosa, setosa, setosa, setos
```

Exercício

Para o conjunto de dados `amostra_enem_salvador.xlsx`, transforme as variáveis `tp_escola` e `tp_cor_raca` em fatores usando a função `fct`.

Matriz

- Agrupamento de valores de mesmo tipo em um único objeto de dimensão 2.
- Criação de matriz:
  - `matrix(..., nrow = <integer>, ncol = <integer>, byrow = TRUE)` - preenche a matriz a partir das linhas se `byrow = TRUE`;
  - `diag(<vector>)` - diagonal principal igual a `<vetor>` e outros elementos zero;
  - `rbind()` - especificação das linhas da matriz;
  - `cbind()` - especificação das colunas da matriz.

Matriz de caracteres

```
matriz_texto <- rbind(c("a", "b"), c("c", "d"))
matriz_texto
```

```
     [,1] [,2]
[1,] "a"  "b"
[2,] "c"  "d"
```

Matriz de números reais

```
matriz_real <- matrix(seq(from = 0, to = 1.5, by = 0.5),
                      nrow = 2, byrow = TRUE)
matriz_real
```

```
     [,1] [,2]
[1,]    0  0.5
[2,]    1  1.5
```

Matriz de inteiros

```
matriz_inteiro <- cbind(c(1L, 2L), c(3L, 4L))
matriz_inteiro
```

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

Matriz de valores lógicos

```
matriz_logico <- matrix(c(TRUE, F, F, T), nrow = 2)
matriz_logico
```

```
      [,1]  [,2]
[1,]  TRUE FALSE
[2,] FALSE  TRUE
```

Array

- Agrupamento de valores de mesmo tipo em um único objeto em duas ou mais dimensões.
- Criação de array: `array(..., dim = <vector of integers>)`.

```
dados_matriz_1 <- 10:13
dados_matriz_2  <- 14:17
resultado <- array(c(dados_matriz_1, dados_matriz_2),
                   dim = c(2, 2, 2))
resultado
```

```
, , 1

     [,1] [,2]
[1,]   10   12
[2,]   11   13

, , 2

     [,1] [,2]
[1,]   14   16
[2,]   15   17
```

Operações com matrizes números (`double`, `integer` e `complex`).

- Operações básicas (operação, substração, multiplicação e divisão) realizada em cada elemento das matrizes.
- Outras operações:
  - Multiplicação de matrizes;
  - Inversão de matrizes;
  - Matriz transposta;
  - Determinante;
  - Solução de sistema de equações lineares.

Matrizes

```
matriz_a <- rbind(c(1, 2), c(0, 3))
matriz_b <- matrix(runif(4), ncol = 2)
```

Soma

```
matriz_soma <- matriz_a + matriz_b
matriz_soma
```

```
          [,1]     [,2]
[1,] 1.5508774 2.425133
[2,] 0.9683276 3.618663
```

Subtração

```
matriz_menos <- matriz_a - matriz_b
matriz_menos
```

```
            [,1]     [,2]
[1,]  0.4491226 1.574867
[2,] -0.9683276 2.381337
```

Produto de Hadamard

- Multiplicação de matrizes, elemento por elemento.
- Para detalhes consulte produto de Hadamard.

```
matriz_hadamard <- matriz_a * matriz_b
matriz_hadamard
```

```
          [,1]      [,2]
[1,] 0.5508774 0.8502655
[2,] 0.0000000 1.8559904
```

Multiplicação de matrizes

```
matriz_multiplicacao <- matriz_a %*% matriz_b
matriz_multiplicacao
```

```
         [,1]    [,2]
[1,] 2.487533 1.66246
[2,] 2.904983 1.85599
```

Matriz inversa

```
matriz_inversa <- solve(matriz_a)
matriz_inversa
```

```
     [,1]       [,2]
[1,]    1 -0.6666667
[2,]    0  0.3333333
```

```
matriz_a %*% matriz_inversa
```

```
     [,1] [,2]
[1,]    1    0
[2,]    0    1
```

Matriz transposta

```
matriz_transposta <- t(matriz_a)
matriz_transposta
```

```
     [,1] [,2]
[1,]    1    0
[2,]    2    3
```

Determinante

```
det(matriz_a)
```

```
[1] 3
```

Solução de sistema de equações lineares

```
b <- c(1, 2)
solve(matriz_a, b)
```

```
[1] -0.3333333  0.6666667
```

Matriz inversa generalizada

G é a matriz inversa generalizada de A se $A \cdot G \cdot A = A$. Para detalhes vide matriz inversa generalizada.

```
library(MASS) # ginv é uma função do pacote MASS
ginv(matriz_a)
```

```
              [,1]       [,2]
[1,]  1.000000e+00 -0.6666667
[2,] -2.775558e-17  0.3333333
```

Outras operações com matrizes.

Operador ou função	Descrição
`A %o% B`	produto diádico $A \cdot B^T$
`crossprod(A, B)`	$A \cdot B^T$
`crossprod(A)`	$A \cdot A^T$
`diag(x)`	retorna uma matrix diagonal com diagonal igual a `x`
`diag(A)`	retorna um vetor com a diagona de A
`diag(k)`	retorna uma matriz diagona de ordem k

Exercício

Realize as seguinte operações envolvendo as matrizes:

1. $\begin{pmatrix} 1 & 0 \\ 2 & 0,5 \end{pmatrix} + \begin{pmatrix} 0,1 & 0 \\ 0 & 0,5 \end{pmatrix}$
2. $\begin{pmatrix} 1 & 0 \\ 2 & 0,5 \end{pmatrix} - \begin{pmatrix} 0,1 & 0 \\ 0 & 0,5 \end{pmatrix}$
3. Multiplicação de matriz: $\begin{pmatrix} 1 & 0 \\ 2 & 0,5 \end{pmatrix} \cdot \begin{pmatrix} 0,1 & 0 \\ 0 & 0,5 \end{pmatrix}$
4. Divisão elemento a elemento: $\begin{pmatrix} 1 & 0 \\ 2 & 0,5 \end{pmatrix} / \begin{pmatrix} 0,1 & 0 \\ 0 & 0,5 \end{pmatrix}$
5. Resolva o seguinte sistema de equações: $\begin{cases} x + 2y = 21 \\ x - 2y = 1 \end{cases}$.
6. Encontre a matriz inversa de $\begin{pmatrix} 1 & 2 \\ 1 & -2 \end{pmatrix}$.

Lista

- Agrupamento de valores de tipos diversos e estrutura de dados
- Criação de listas: `list(...)` e `vector("list", <comprimento da lista>)`

```
lista_info <- list(pedido_id = 8001406,
          nome = "Fulano",
          sobrenome = "de Tal",
          cpf = "12345678900",
          itens = list(list(descricao = "Ferrari",
                            frete = 0,
                            valor = 500000),
                       list(descricao = "Dolly", frete = 1.5,
                            valor = 3.90)))
lista_info
```

```
$pedido_id
[1] 8001406

$nome
[1] "Fulano"

$sobrenome
[1] "de Tal"

$cpf
[1] "12345678900"

$itens
$itens[[1]]
$itens[[1]]$descricao
[1] "Ferrari"

$itens[[1]]$frete
[1] 0

$itens[[1]]$valor
[1] 5e+05


$itens[[2]]
$itens[[2]]$descricao
[1] "Dolly"

$itens[[2]]$frete
[1] 1.5

$itens[[2]]$valor
[1] 3.9
```

Estrutura de dados heterogênea
Exercício

Crie uma lista, chamada `informacoes_pessoais` com os seguintes campos:

- `nome`: seu nome
- `idade`: sua idade
- `informacao_profissional`: uma lista com os seguintes campos:
  - `matricula`: escolaridade
  - `origem`: variável qualitativa com a sua cidade de origem.
- `matriz`: inclua uma matriz de números reais de dimensão 2×2

- *slicing* - `[]` - extrai parte da lista (valor retornado é uma lista).
- Acessando *k*-ésimo valor da lista: `lista[[k]]`.
- Acessando um valor da lista pela chave (nome do campo): `lista$cpf`.
- Concatenação de listas: `c()`.

Slicing

```
lista_info[c(2, 4)]
```

```
$nome
[1] "Fulano"

$cpf
[1] "12345678900"
```

Acessando elemento pela posição

```
lista_info[[2]]
```

```
[1] "Fulano"
```

Acessando elemento pela chave

```
lista_info$nome
```

```
[1] "Fulano"
```

Concatenação de listas

```
lista_1 <- list(1, 2)
lista_2 <- list("Gilberto", "Sassi")
lista_concatenada <- c(lista_1, lista_2)
lista_concatenada
```

```
[[1]]
[1] 1

[[2]]
[1] 2

[[3]]
[1] "Gilberto"

[[4]]
[1] "Sassi"
```

Estrutura de dados heterogênea
Exercício

Recupe e imprima as seguintes informações da lista `informacoes_pessoais`:

- os três primeiros campos de `informacoes_pessoais`
- os nomes dos campos de `informacoes_pessoais`
- campo `nome` de `informacoes_pessoais`
- o terceiro campo de `informacoes_pessoais`

Tidy data

- Dados em formato de tabela.
- Cada coluna é uma variável e cada linha é uma observação.

`tibble` (data frame)

- Estrutura de dados tabular.
- Assumimos que os dados estão **tidy**.
- Criação de `tibble`: `tibble(...)` e `tribble(....)`.
- `glimpse` mostra as informações do `tibble`.

```r
library(tidyverse) # carregando o framework tidyverse
data_frame <- tibble(
  nome = c("Marx", "Engels", "Rosa", "Lênin", "Olga Benário"),
  idade = c(22, 23, 21, 24, 30)
)
glimpse(data_frame)
```

```
Rows: 5
Columns: 2
$ nome  <chr> "Marx", "Engels", "Rosa", "Lênin", "Olga Benário"
$ idade <dbl> 22, 23, 21, 24, 30
```

Valores especiais em R

Valores especiais	Descrição	Função para identificar
`NA`	Valor faltante.	`is.na()`
`NaN`	Resultado do cálculo indefinido.	`is.nan()`
`Inf`	Valor que excede o valor máximo que sua máquina aguenta.	`is.inf()`
`NULL`	Valor indefinido de expressões e funções (diferente de `NaN` e `NA`)	`is.null()`

Operações básicas em um `tibble`

Função	Descrição
`head()`	Mostra as primeiras linhas de um `tibble`
`tail()`	Mostra as últimas linhas de um `tibble`
`glimpse()`	Impressão de informações básicas dos dados
`add_case()`	Adiciona uma nova observação
`add_row()`	Adiciona uma nova observação

```r
head(data_frame, n=2)
```

```
# A tibble: 2 x 2
  nome   idade
  <chr>  <dbl>
1 Marx      22
2 Engels    23
```

```r
tail(data_frame, n=2)
```

```
# A tibble: 2 x 2
  nome          idade
  <chr>         <dbl>
1 Lênin            24
2 Olga Benário     30
```

Estrutura de dados heterogênea
Exercício

Realize as seguintes operações no *dataset* `iris` (disponível no `R`):

- imprima um resumo sobre o *dataset* `iris`.
- pegue as 5 primeiras linhas de `iris`.
- pegue as 5 últimas linhas de `iris`.
- crie *na mão* o seguinte conjunto de dados:

nomes	origem
Fidel Castro	Cuba
Ernesto 'Che' Guevara	Cuba
Célia Sánchez	Cuba

Organização é fundamental

Departamento de Estatística
IME - UFBA

O nome de um objeto precisa ter um *significado*.

O nome deve indicar e deixar claro o que este objeto é ou faz.

- Use a convenção do R:
  - Use apenas letras minúsculas, números e *underscore* (comece sempre com letras minúsculas).
  - Nomes de objetos precisam ser substantivos e precisam descrever o que este objeto é ou faz (seja conciso, direto e significativo).
  - Evite ao máximo os nomes que já são usados (*buit-in*) do R.Por exemplo: `c`.
  - Coloque espaço depois da vírgula.
  - Não coloque espaço antes nem depois de parênteses. Exceção: Coloque um espaço `()` antes e depois de `if`, `for` ou `while`, e coloque um espaço depois de `()`.
  - Coloque espaço entre operadores básicos: `+`, `-`, `*`, `==` e outros. Exceção: `^`.

Estrutura de diretórios

Mantenha uma estrutura (organização) consistente de diretórios em seus projetos.

- Sugestão de estrutura:
  - `dados`: diretório para armazenar seus conjuntos de dados.
    - `brutos`: dados brutos.
    - `processados`: dados processados.
  - `scripts`: código fonte do seu projeto.
  - `figuras`: figuras criadas no seu projeto.
  - `output`: outros arquivos que não são figuras.
  - `legado`: arquivos da versão anterior do projeto.
  - `notas`: notas de reuniões e afins.
  - `relatorio` (ou `artigos`): documento final de seu projeto.
  - `documentos`: livros, artigos e qualquer coisa que são referências em seu projeto.

Para mais detalhes, consulte esse guia do curso-r: diretórios e `.Rproj`.

Importação e exportação de dados

Departamento de Estatística
IME - UFBA

Leitura de arquivos no formato `xlsx` ou `xls`

- **Pacote:** `readxl`
- Parêmetros das funções `read_xls` (arquivos `.xls`) e `read_xlsx` (arquivos `.xlsx`):
  - `path`: caminho até o arquivo.
  - `sheet`: especifica a planilha do arquivo que será lida.
  - `range`: especifica uma área de uma planilha para leitura. Por exemplo: `B3:E15`.
  - `col_names`: Argumento lógico com valor padrão igual a `TRUE`. Indica se a primeira linha tem o nome das variáveis.

Para mais detalhes, consulte a documentação: documentação de `read_xl`.

Leitura de arquivos no formato `xlsx` ou `xls`

```
library(tidyverse)
library(readxl)
dados_iris <- read_xlsx("dados/brutos/iris.xlsx")
dados_iris <- clean_names(dados_iris)

glimpse(dados_iris)
```

```
Rows: 150
Columns: 5
$ comprimento_sepala <dbl> 5.1, 4.9, 4.7, 4.6, 5.0, 5.4, 4.6, 5.0, 4.4,
$ largura_sepala     <dbl> 3.5, 3.0, 3.2, 3.1, 3.6, 3.9, 3.4, 3.4, 2.9,
$ comprimento_petala <dbl> 1.4, 1.4, 1.3, 1.5, 1.4, 1.7, 1.4, 1.5, 1.4,
$ largura_petala     <dbl> 0.2, 0.2, 0.2, 0.2, 0.2, 0.4, 0.3, 0.2, 0.2,
$ especies           <chr> "setosa", "setosa", "setosa", "setosa", "set
```

Lendo dados no R
Exercício

Leia o *dataset* `dados_leitura.xlsx` usando o pacote `readxl`.

As formatações dos arquivos `csv`

- `csv`: *comma separated values* (valores separados por coluna). O *separador* varia em diferentes sistemas de medidas.

- No sistema métrico:
  - As casas decimais são separadas por ,
  - O agrupamento de milhar é marcada por .
  - As colunas dos arquivos de texto são separadas por ;

- No sistema imperial inglês (UK e USA):
  - As casas decimais são separadas por .
  - O agrupamento de milhar é marcada por ,
  - As colunas dos arquivos de texto são separadas por ,

Preste atenção em como o seus dados estão armazenados!

Leitura de arquivos no formato `csv`

- **Pacote:** `readr` do `tidyverse` (instale com o comando `install.packages('readr')`).
- Parêmetros das funções `read_csv` (sistema imperial inglês) e `read_csv2` (sistema métrico):
  - `path`: caminho até o arquivo.

Para mais detalhes, consulte a documentação oficial do *tidyverse*: documentação de `read_r`.

Leitura de arquivos no formato csv

```
dados_mtcarros <- read_csv2("dados/brutos/mtcarros.csv")
dados_mtcarros <- clean_names(dados_mtcarros)
glimpse(dados_mtcarros)
```

```
Rows: 32
Columns: 11
$ milhas_por_galao <dbl> 21.0, 21.0, 22.8, 21.4, 18.7, 18.1, 14.3, 24.4, 22.8,~
$ cilindros        <dbl> 6, 6, 4, 6, 8, 6, 8, 4, 4, 6, 6, 8, 8, 8, 8, 8, 8, 4,~
$ cilindrada       <dbl> 160.0, 160.0, 108.0, 258.0, 360.0, 225.0, 360.0, 146.~
$ cavalos_forca    <dbl> 110, 110, 93, 110, 175, 105, 245, 62, 95, 123, 123, 1~
$ eixo             <dbl> 3.90, 3.90, 3.85, 3.08, 3.15, 2.76, 3.21, 3.69, 3.92,~
$ peso             <dbl> 2.620, 2.875, 2.320, 3.215, 3.440, 3.460, 3.570, 3.19~
$ velocidade       <dbl> 16.46, 17.02, 18.61, 19.44, 17.02, 20.22, 15.84, 20.0~
$ forma            <dbl> 0, 0, 1, 1, 0, 1, 0, 1, 1, 1, 1, 0, 0, 0, 0, 0, 0, 1,~
$ transmissao      <dbl> 1, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1,~
$ marchas          <dbl> 4, 4, 4, 3, 3, 3, 3, 4, 4, 4, 4, 3, 3, 3, 3, 3, 3, 4,~
$ carburadores     <dbl> 4, 4, 1, 1, 2, 1, 4, 2, 2, 4, 4, 3, 3, 3, 4, 4, 4, 1,~
```

Lendo dados no R
Exercício

Leia o *dataset* `dados_leitura.csv` usando o pacote `readr`.

Leitura de arquivos no formato `ods`

- **Pacote:** `readODS` (instale com o comando `install.packages('readODS')`).
- Parêmetros das funções `read_ods`:
- `path`: caminho até o arquivo.
  - `sheet`: especifica a planilha do arquivo que será lida.
  - `range`: especifica uma área de uma planilha para leitura. Por exemplo: `B3:E15`.
  - `col_names`: Argumento lógico com valor padrão igual a `TRUE`. Indica se a primeira linha tem o nome das variáveis.

Para mais detalhes, consulte a documentação do *readODS*: documentação de `readODS`.

Leitura de arquivos no formato ods

```
library(readODS)
dados_dentes <- read_ods("dados/brutos/crescimento_dentes.ods")
dados_dentes <- clean_names(dados_dentes)

glimpse(dados_dentes)
```

```
Rows: 60
Columns: 3
$ comprimento <dbl> 4.2, 11.5, 7.3, 5.8, 6.4, 10.0, 11.2, 11.2,
$ suplemento  <chr> "Vitamina C", "Vitamina C", "Vitamina C", "V
$ dose        <dbl> 0.5, 0.5, 0.5, 0.5, 0.5, 0.5, 0.5, 0.5, 0.5,
```

Lendo dados no R
Exercício

Leia o *dataset* `dados_leitura.ods` usando o pacote `readODS`.

Salvar no formato `.csv` (sistema métrico)

`write_csv2` é parte do pacote `readr`.

```
write_csv2(dados_dentes, file = "dados/processados/nome.csv")
```

Salvar no formato `.xlsx`

`write_xlsx` é parte do pacote `writexl`.

```
write_xlsx(dados_dentes, path = "dados/processados/nome.xlsx")
```

Salvar no formato `ods`

`write_ods` é parte do pacote `readODS`.

```
write_ods(dados_toothgrowth, path = "dados/processados/nome.ods")
```

Salvando dados no R
Exercício

1. Salve o objeto `milhas` do pacote `dados` como `milhas.ods` na pasta `output` do seu projeto.
2. Salve o objeto `diamante` do pacote `dados` como `diamante.csv` na pasta `output` do seu projeto.
3. Salve o objeto `velho_fiel` do pacote `dados` como `velho_fiel.xlsx` na pasta `output` do seu projeto.

O operador pipe
|>

O valor resultante da expressão do lado esquerdo vira primeiro argumento da função do lado direito.

Principal vantagem: simplifica a leitura e a documentação de funções compostas.

Executar

```
f(x, y)
```

é exatamente a mesma coisa que executar

```
x |> f(y)
```

```r
log(sqrt(sum(x^2)))
```

é exatamente a mesma coisa que executar

```r
x^2 |> sum() |> sqrt() |> log()
```

Fazendo um bolo

Exemplo adaptado de 6.1 O operador pipe.

Para cozinhar o bolo precisamos usar as seguintes funções:

- `acrescente(lugar, algo)`
- `misture(algo)`
- `asse(algo)`

Fazendo um bolo

- Passo 1:

```
acrescente(
  "tigela vazia",
  "farinha"
)
```

- Passo2:

```
acrescente(
  acrescente(
    "tigela vazia",
    "farinha"
  ),
  "ovos"
)
```

- Passo3:

```
acrescente(
  acrescente(
    acrescente(
      "tigela vazia",
      "farinha"
    ),
    "ovos"
  ),
  "leite"
)
```

- Passo4:

```
acrescente(
  acrescente(
    acrescente(
      acrescente(
        "tigela vazia",
        "farinha"
      ),
      "ovos"
    ),
    "leite"
  ),
  "fermento"
)
```

- Passo 5:

```
misture(
  acrescente(
    acrescente(
      acrescente(
        acrescente(
          acrescente(
            "tigela vazia",
            "farinha"
          ),
          "ovos"
        ),
        "leite"
      ),
      "fermento"
  )
)
```

- Passo 6:

```
asse(
  misture(
    acrescente(
      acrescente(
        acrescente(
          acrescente(
            "tigela vazia",
            "farinha"
          ),
          "ovos"
        ),
        "leite"
      ),
      "fermento"
    )
  )
)
```

Usando o operador |>.

```
acrescente("tigela vazia", "farinha") |>
  acrescente("ovos") |>
  acrescente("leite") |>
  acrescente("fermento") |>
  misture() |>
  asse()
```

Função

- Evita repetição do mesmo código na análise de dados.
- Se você um mesmo pedaço de código, fica mais simples a atualização deste pedaço de código.
- Evita erros ao fazermos `ctrl+c` e `ctrl+v`.
- Facilita a reutilização de código em outros projetos.

Se você fizer `ctrl+c` e `ctrl+v` duas ou mais vezes, escreva uma função!

Esta seção foi adaptada do livro R for Data Science.

Função
motivação

Considere a medida de assimetria descrita por

```
assimetria = (quantile(x, 0.95) - 2 * median(x) + quantile(x, 0.05)) /
      (quantile(x, 0.95) - quantile(x, 0.05))
```

- `assimetria < 0` se e somente se `x` tem assimetria à esquerda ou negativa;
- `assimetria > 0` se e somente se `x` tem assimetria à direita ou positiva;
- `assimetria == 0` se e somente se `x` tem simetria.

Vamos calcular essa medida para cada variável quantitativa do conjunto de dados `iris2.xlsx`.

```r
dados_iris <- read_csv2("dados/brutos/iris2.csv")

df_assimetria <- dados_iris |>
  summarise(
    ass_larg_sep = (quantile(larg_sep, 0.95) - 2 * median(larg_sep) +
                    quantile(larg_sep, 0.05)) /
      (quantile(larg_sep, 0.95) - quantile(larg_sep, 0.05)),
    ass_comp_sep = (quantile(comp_sep, 0.95) - 2 * median(comp_sep) +
                    quantile(comp_sep, 0.05)) /
      (quantile(comp_sep, 0.95) - quantile(comp_sep, 0.05)),
    ass_larg_pet = (quantile(larg_pet, 0.95) - 2 * median(larg_pet) +
                    quantile(larg_pet, 0.05)) /
      (quantile(larg_pet, 0.95) - quantile(larg_pet, 0.05)),
    ass_comp_pet = (quantile(comp_pet, 0.95) - 2 * median(comp_pet) +
                    quantile(comp_pet, 0.05)) /
      (quantile(comp_pet, 0.95) - quantile(comp_pet, 0.05))
  )
```

```
df_assimetria
```

```
# A tibble: 1 x 4
  ass_larg_sep ass_comp_sep ass_larg_pet ass_comp_pet
         <dbl>        <dbl>        <dbl>        <dbl>
1       0.0960       0.0997       -0.271      -0.0476
```

Largura de pétala tem assimetria à esquerda ou negativa.

Repetimos quatro vezes o cálculo da medida de assimetria.

precisamos criar uma função!

Uma função é composta por três partes:

- `nome`: nome para o pedaço de código;
- `argumentos`: informações necessárias para execução do pedaço de código;
- `corpo`: pedaço de código.

Em `corpo`, geralmente incluímos a função `return(<objeto>)`.

Se a função não tiver `return(<objeto>)`, valor da última linha será retornado.

Escrevemos uma função da seguinte forma:

```
nome <- function(arg1, arg2, arg3 = <valor padrão>, arg4 = <valor padrão>) {
  corpo
}
```

Vamos reescrever o código do cálculo de assimetria.

```
dados_iris <- read_csv2("dados/brutos/iris2.csv")

ass <- function(x) {
  q_lower <- quantile(x, 0.05)
  q_upper <- quantile(x, 0.95)
  m <- median(x)

  (q_upper - 2 * m + q_lower) / (q_upper - q_lower)
}

df_assimetria <- dados_iris |>
  summarise(
    ass_larg_sep = ass(larg_sep), ass_comp_sep = ass(comp_sep),
    ass_larg_pet = ass(larg_pet), ass_comp_pet = ass(comp_pet)
  )
df_assimetria
```

```
# A tibble: 1 x 4
  ass_larg_sep ass_comp_sep ass_larg_pet ass_comp_pet
         <dbl>        <dbl>        <dbl>        <dbl>
1       0.0960       0.0997       -0.271      -0.0476
```

Se mudassemos o coeficiente de assimetria para:

```
assimetria = (quantile(x, 0.99) - 2 * median(x) + quantile(x, 0.01)) /
      (quantile(x, 0.99) - quantile(x, 0.01))
```

```
dados_iris <- read_csv2("dados/brutos/iris2.csv")

ass <- function(x) {
  q_lower <- quantile(x, 0.01)
  q_upper <- quantile(x, 0.99)
  m <- median(x)

  (q_upper - 2 * m + q_lower) / (q_upper - q_lower)
}

df_assimetria <- dados_iris |>
  summarise(
    ass_larg_sep = ass(larg_sep), ass_comp_sep = ass(comp_sep),
    ass_larg_pet = ass(larg_pet), ass_comp_pet = ass(comp_pet)
  )
df_assimetria
```

```
# A tibble: 1 x 4
  ass_larg_sep ass_comp_sep ass_larg_pet ass_comp_pet
         <dbl>        <dbl>        <dbl>        <dbl>
1        0.152        0.180       -0.153    -3.47e-17
```

Para `amostra_enem_salvador.xlsx`, use o seguinte código

```
((x - min(x)) * 10) / (max(x) - min(x))
```

para repadronizar (de 0 a 10) as seguintes variáveis: `nu_nota_cn`, `nu_nota_ch`, `nu_nota_lc`, `nu_nota_mt`, `nu_nota_comp1`, `nu_nota_comp2`, `nu_nota_comp3`, `nu_nota_comp4`, `nu_nota_comp5`, e `nu_nota_redacao`.

Controle de fluxo

Departamento de Estatística
IME - UFBA

Controle de fluxo

Controle de fluxo para vetores, listas e matrizes.

- `if else`;
- `for`;
- `while`;
- `case_when`;
- `sapply`, `apply` e `vapply`;
- família de funções `map_*`, onde `*` é `chr`, `dbl`, `int`, `df` e `lgl`.

Controle de fluxo
if else e for

if else

```
if (<expressao>) {
  <bloco de código>
} else if (<expressao>) {
  <bloco de código>
} else if (<expressao>) {
  <bloco de código>
} else {
  <bloco de código>
}
```

---

for

```
for (k in <vetor or lista>) {
  <bloco de código>
}
```

Considere a variável aleatória discreta com função de probabilidade dada por:

x	f(x)
1	0,4
3	0,25
10	0,35

Gere uma amostra aleatória com 1000 observações de X.

```r
amostra_x <- vector("integer", 1000)
for (k in 1:1000) {
  valor_aleatorio <- runif(1)
  if (valor_aleatorio <= 0.4) {
    amostra_x[k] <- 1
  } else if (0.4 < valor_aleatorio & valor_aleatorio <= 0.65) {
    amostra_x[k] <- 3
  } else {
    amostra_x[k] <- 10
  }
}

table(amostra_x) / 1000
```

```
amostra_x
    1     3    10
0.399 0.269 0.332
```

while

```
while (<expressão lógica>) {
  <bloco de código>
}
```

- Para sair de um laço `for`, usamos `break`.
- Para o restando do bloco de código e ir para o próximo passo laço, usamos `continue`.

Controle de fluxo
`if else` e `while`

Considere $X \sim N(2, 4)$ truncado com valor 0 e 4: $X \mid 0 \leq X \leq 4$.

Gere uma amostra aleatória com 1000 observações de X.

```
amostra_x <- vector("double", 1000)
for (k in seq_len(1000)) {
  while (TRUE) {
    valor_aleatorio <- rnorm(1, 2, 2)
    if (between(valor_aleatorio, 0, 4)) {
      amostra_x[k] <- valor_aleatorio
      break
    }
  }
}
summary(amostra_x)
```

```
    Min.  1st Qu.   Median     Mean  3rd Qu.     Max.
0.004917 1.103885 1.953375 1.965194 2.820515 3.981617
```

Departamento de Estatística
IME - UFBA

Versão mais rápida e mais simples de ler do seguinte código:

```
resultado <- vector("double", length(sequencia))
for (k in sequencia) {
  resultado[k] <- funcao(k)
}
```

---

sapply

- sapply cria um vetor se funcao retorna um escalar;
- sapply cria uma matriz se funcao retorna um vetor.

```
resultado <- sapply(sequencia, funcao)
```

lapply

lapply cria uma lista.

```
resultado <- lapply(sequencia, funcao)
```

vapply

Precisamos apresentar um modelo de valor retornado de `funcao`. Este modelo pode um escalar, um vetor ou uma matriz (neste caso `resultado` será um `array`).

```
resultado <- vapply(sequencia, funcao, modelo)
```

Função anônima

É comum criamos uma função *simples* para usar apenas uma vez com `sapply`, `lapply` e `vapply`.
Neste caso podemos criar uma função anônima:

```
\(x) <código>
```

ou

```
\(x) {
  <bloco de código>
}
```

Exemplo

Vamos padronizar as variáveis do conjunto de dados `mtcarros.xlsx`.

```
dados_carros <- read_csv2("dados/brutos/mtcarros.csv")
m_carros <- dados_carros |>
  select(where(is.numeric)) |>
  sapply(\(x) (x - mean(x)) / sd(x))
class(m_carros)
```

```
[1] "matrix" "array"
```

```
dim(m_carros)
```

```
[1] 32 11
```

Exemplo

Suponha que queremos calcular a média, a mediana e o desvio padrão para as variáveis `milhas_por_galao`, `cilindros` e `velocidade` do conjunto de dados `mtcarros.xlsx`

```
sumario <- dados_carros |>
  select(milhas_por_galao, cilindros, velocidade) |>
  vapply(
    \(x) c("Média" = mean(x), "Mediana" = median(x), "DP" = sd(x)),
    c(0,0,0)
  )
class(sumario)
```

```
[1] "matrix" "array"
```

```
sumario
```

```
        milhas_por_galao cilindros velocidade
Média           20.090625  6.187500  17.848750
Mediana         19.200000  6.000000  17.710000
DP               6.026948  1.785922   1.786943
```

Exemplo

```
medias_carros <- dados_carros |>
  select(milhas_por_galao, cilindros, velocidade) |>
  lapply(\(coluna) mean(coluna))
class(medias_carros)
```

```
[1] "list"
```

```
medias_carros
```

```
$milhas_por_galao
[1] 20.09062

$cilindros
[1] 6.1875

$velocidade
[1] 17.84875
```

Controle de fluxo
`sapply`, `lapply` e `vapply`

Exercício

- Calcule a média, a mediana, e o desvio padrão para as notas do conjunto de dados `amostra_enem_salvador.xlsx` (variáveis que começam com `nu_nota_`). Use `sapply`.
- Crie um `array` com a média, a mediana, mínimo e o máximo para largura e comprimento das pétalas e sépalas do conjunto de dados `iris.xlsx`. Use `vapply`.
- Crie uma lista com a moda das variáveis `tp_sexo`, `tp_cor_raca` e `tp_escola` do conjunto de dados `amostra_enem_salvador.xlsx`. Use `lapply`.

`map_*`

Equivalente das funções `sapply`, `lapply` e `vapply` do *framework* `tidyverse`.

Principais melhorias: consistências na família `map_` e documentação (explicita o valor retornado).

- `map(sequencia, funcao)`: equivalente a `lapply`;
- `map_chr(sequencia, funcao)`: produz um vetor de *strings*:
  - equivalente a `vapply(sequencia, funcao, 'texto')`;
  - `funcao` retorna um escalar do tipo `character`;
- `map_dbl(sequencia, funcao)`: produz um vetor de números reais:
  - equivalente a `vapply(sequencia, funcao, 1.11)`;
  - `funcao` retorna um escalar do tipo `numeric`;

- `map_int(sequencia, funcao)`: produz um vetor de números inteiros:
  - equivalente a `vapply(sequencia, funcao, 1.11)`;
  - `funcao` retorna um escalar do tipo `integer`;
- `map_lgl(sequencia, funcao)`: produz um vetor de valores lógicos:
  - equivalente a `vapply(sequencia, funcao, TRUE)`;
  - `funcao` retorna um escalar do tipo `logical`;
- `map_df(tibble, funcao)`: produz um `tibble`:
  - `funcao` retorna um vetor com o tamanho `nrow(tibble)`.

Exemplo

Vamos calcular o quantil de ordem 60% para as variáveis do conjunto de dados `mtcarros.xlsx`

```
dados_carros <- read_excel("dados/brutos/mtcarros.xlsx")
medias_carros <- dados_carros |>
  select(where(is.numeric)) |>
  map_dbl(\(variavel) quantile(variavel, 0.60))
class(medias_carros)
```

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

```
medias_carros
```

```
milhas_por_galao        cilindros      cilindrada    cavalos_forca
            21.0              8.0            275.0            165.0
          forma      transmissao          marchas     carburadores
            1.0              0.6              4.0              3.0
```

Exemplo

Padronize as variáveis quantitativas do conjunto de dados `mtcarros.xlsx`.

```
dados_carros <- read_excel("dados/brutos/mtcarros.xlsx")
df_carros_padronizada <- dados_carros |>
  select(where(is.numeric)) |>
  map_df(\(variavel) (variavel - mean(variavel)) / sd(variavel))
glimpse(df_carros_padronizada)
```

```
Rows: 32
Columns: 8
$ milhas_por_galao <dbl> 0.2188603, 0.2188603, 0.3856111, 0.2188
$ cilindros        <dbl> -0.1049878, -0.1049878, -1.2248578, -0.
$ cilindrada       <dbl> -0.56836598, -0.56836598, -0.98758628,
$ cavalos_forca    <dbl> -0.53509284, -0.53509284, -0.78304046,
$ forma            <dbl> -0.8680278, -0.8680278, 1.1160357, 1.11
$ transmissao      <dbl> 1.1899014, 1.1899014, 1.1899014, -0.814
$ marchas          <dbl> 0.4235542, 0.4235542, 0.4235542, -0.931
$ carburadores     <dbl> 0.7352031, 0.7352031, -1.1221521, -1.12
```

Transformações nos dados

Departamento de Estatística
IME - UFBA

Transformações nos dados

Objetivo: Transformações em um objeto `tibble`.

Transformações que veremos neste curso:

1. seleção de observações (linhas);
2. seleção de variáveis (colunas);
3. criação de novas colunas;
4. ordenação de linhas;
5. transposição de linhas para colunas;
6. transposição de colunas para linhas.

Vamos usar o conjunto de dados `voos.xlsx` que todos os voos que decolaram no horários na cidade de Nova Iorque nos EUA.

No *framwework* `tidyverse` (especialmente no pacote `dplyr`), temos que

1. O primeiro argumento é sempre um `data frame` (objeto da classe `tibble`);
2. Os outros argumentos tipicamente descrecem quais colunas para realizar as operações, e essas colunas são indicadas pelo nome sem aspas;
3. O resultado sempre é sempre um `data frame` (objeto da classe `tibble`);
4. Chama-se de *verbo* funções que agem sobre base de dados;
5. Para resolver problemas reais, combinamos vários *verbos* usando operador `|>`.
6. Os *verbos* são classificados em quarto categorias: **linhas**, **colunas**, **grupos** e **tabelas**.

Transformações nos dados
linhas

Principais *verbos*:

- `filter()`: seleciona linhas baseadas de condições envolvendo colunas;
- `arrange()`: ordena linhas de acordo com alguma(s) coluna(s);
- `distinct()`: remove linhas com repetições segundo algumas(s) coluna(s).

Transformações nos dados
`filter()`

Usamos operadores lógicos para selecionar linhas segundo alguma condições envolvendo colunas:

- desigualdades: `>`, `<`, `<=`, `>=`, `==`, `!=`;
- combinações de expressões lógicas: `&` (e), `|` (ou);
- checa se valor está em um vetor: `%in%`. Exemplo, `'Gilberto' %in% equipe` retorna `TRUE`;

Vamos selecionar os voos que sairam de Nova York no feriado de ano novo.

```
df_voos <- read_excel('dados/brutos/voos.xlsx')

df_voos_ano_novo <- df_voos |>
  filter(mes == 1 & dia == 1)
glimpse(df_voos_ano_novo)
```

```
Rows: 842
Columns: 19
$ ano              <dbl> 2013, 2013, 2013, 2013, 2013, 2013, 2013, 2013
$ mes              <dbl> 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1
$ dia              <dbl> 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1
$ horario_saida    <dbl> 517, 533, 542, 544, 554, 554, 555, 557, 557, 5
$ saida_programada <dbl> 515, 529, 540, 545, 600, 558, 600, 600, 600, 6
$ atraso_saida     <dbl> 2, 4, 2, -1, -6, -4, -5, -3, -3, -2, -2, -2, -
$ horario_chegada  <dbl> 830, 850, 923, 1004, 812, 740, 913, 709, 838,
$ chegada_prevista <dbl> 819, 830, 850, 1022, 837, 728, 854, 723, 846,
$ atraso_chegada   <dbl> 11, 20, 33, -18, -25, 12, 19, -14, -8, 8, -2,
$ companhia_aerea  <chr> "UA", "UA", "AA", "B6", "DL", "UA", "B6", "EV"
$ voo              <dbl> 1545, 1714, 1141, 725, 461, 1696, 507, 5708, 7
$ cauda            <chr> "N14228", "N24211", "N619AA", "N804JB", "N668D
$ origem           <chr> "EWR", "LGA", "JFK", "JFK", "LGA", "EWR", "EWR
$ destino          <chr> "IAH", "IAH", "MIA", "BQN", "ATL", "ORD", "FLL
$ tempo_voo        <dbl> 227, 227, 160, 183, 116, 150, 158, 53, 140, 13
$ distancia        <dbl> 1400, 1416, 1089, 1576, 762, 719, 1065, 229, 9
$ hora             <dbl> 5, 5, 5, 5, 6, 5, 6, 6, 6, 6, 6, 6, 6, 6, 6, 5
$ minuto           <dbl> 15, 29, 40, 45, 0, 58, 0, 0, 0, 0, 0, 0, 0, 0,
$ data_hora        <dttm> 2013-01-01 10:00:00, 2013-01-01 10:00:00, 201
```

Transformações nos dados
arrange()

- Se mais de uma coluna é usada, as colunas adicionais são usadas para desempatar a ordenação.
- Para ordenar em ordem decrescente (maior ao menor), use a função `desc()`.

```
df_voos_ordenado <- df_voos |>
  arrange(mes, desc(dia), desc(horario_saida))
head(df_voos_ordenado, 5)
```

```
# A tibble: 5 x 19
    ano   mes   dia horario_saida saida_programada atraso_saida
  <dbl> <dbl> <dbl>         <dbl>             <dbl>        <dbl>
1  2013     1    31          2354              2055          179
2  2013     1    31          2330              2159           91
3  2013     1    31          2324              1905          259
4  2013     1    31          2312              2159           73
5  2013     1    31          2310              2105          125
# i 12 more variables: chegada_prevista <dbl>, atraso_chegada <d
#   companhia_aerea <chr>, voo <dbl>, cauda <chr>, origem <chr>,
#   tempo_voo <dbl>, distancia <dbl>, hora <dbl>, minuto <dbl>,
#   data_hora <dttm>
```

Transformações nos dados
`distinct()`

- Remove linhas repetidas.
- A primeira ocorrência das linhas repetidas será mantida, e todas as outras ocorrências serão descartadas.

Exemplo:

```
coordenadores <- tribble(
  ~nome, ~email, ~funcao,
  "Gilberto", "gilberto.sassi@ufba.br", "coordenador",
  "Gilberto", "gilberto.sassi@ufba.br", "professor",
  "Gilberto", "gilberto.sassi@ufba.br", "professor",
  "Carolina", "carolina.paraiba@ufba.br", "coordenadora",
  "Carolina", "carolina.paraiba@ufba.br", "professora",
  "Carolina", "carolina.paraiba@ufba.br", "professora"
)
```

Tiramos a repetição das linhas.

```
distinct(coordenadores)
```

```
# A tibble: 4 x 3
  nome     email                      funcao
  <chr>    <chr>                      <chr>
1 Gilberto gilberto.sassi@ufba.br     coordenador
2 Gilberto gilberto.sassi@ufba.br     professor
3 Carolina carolina.paraiba@ufba.br   coordenadora
4 Carolina carolina.paraiba@ufba.br   professora
```

Tiramos a repetição por e-mail.

```
distinct(coordenadores, email, .keep_all = TRUE)
```

```
# A tibble: 2 x 3
  nome      email                       funcao
  <chr>     <chr>                       <chr>
1 Gilberto  gilberto.sassi@ufba.br      coordenador
2 Carolina  carolina.paraiba@ufba.br    coordenadora
```

Transformações nos dados
Exercício

Para o conjunto de dados `amostra_enem_salvador.xlsx`, realiza as seguintes operações:

- selecione todas/os candidatas/os que são `pardas`, `pretas` e `indígenas` (`tp_cor_raca`);
- ordene as/os candidatas/os pela nota em matemática (`nu_nota_mt`).

Transformações nos dados
colunas

Principais *verbos*:

- `mutate()`: adiciona uma nova coluna ao `data.frame`;
- `select()`: selecionar colunas de um `data.frmae`;
- `rename()`: atualize os nomes das colunas de um `data.frame`;
- `relocate()`: mude a ordem das colunas.

Transformações nos dados
`mutate()`

`mutate` adiciona a coluna a direita da última coluna. Podemos usar os seguintes argumentos nomeados:

- `.before`: número inteiro positivo (indicado a posição da coluna) ou o nome da coluna. A nova coluna será incluído a esquerda.
- `.after`: número inteiro positivo (indicado a posição da coluna) ou o nome da coluna. A nova coluna será incluído a direita.

```
df_voos <- df_voos |>
  mutate(velocidade = distancia / tempo_voo, .before = "ano")
```

```r
head(df_voos, n=5)
```

```
# A tibble: 5 x 20
  velocidade   ano   mes   dia horario_saida saida_programada at
       <dbl> <dbl> <dbl> <dbl>         <dbl>             <dbl>
1       6.17  2013     1     1           517               515
2       6.24  2013     1     1           533               529
3       6.81  2013     1     1           542               540
4       8.61  2013     1     1           544               545
5       6.57  2013     1     1           554               600
# i 13 more variables: horario_chegada <dbl>, chegada_prevista <
#   atraso_chegada <dbl>, companhia_aerea <chr>, voo <dbl>, caud
#   origem <chr>, destino <chr>, tempo_voo <dbl>, distancia <dbl
#   minuto <dbl>, data_hora <dttm>
```

Transformações nos dados
`select()`

Seleção de colunas pelo nome e/ou por *atalhos*.

Seleção por nomes das colunas.

```
df_select <- df_voos |>
  select(ano, mes, dia)
glimpse(df_select)
```

```
Rows: 336,776
Columns: 3
$ ano <dbl> 2013, 2013, 2013, 2013, 2013, 2013, 2013, 2013, 2013
$ mes <dbl> 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1
$ dia <dbl> 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1
```

Seleção de todas as colunas entre duas variáveis.

```
df_select <- df_voos |>
  select(ano:voo)
glimpse(df_select)
```

```
Rows: 336,776
Columns: 11
$ ano              <dbl> 2013, 2013, 2013, 2013, 2013, 2013, 201
$ mes              <dbl> 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1,
$ dia              <dbl> 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1,
$ horario_saida    <dbl> 517, 533, 542, 544, 554, 554, 555, 557,
$ saida_programada <dbl> 515, 529, 540, 545, 600, 558, 600, 600,
$ atraso_saida     <dbl> 2, 4, 2, -1, -6, -4, -5, -3, -3, -2, -2
$ horario_chegada  <dbl> 830, 850, 923, 1004, 812, 740, 913, 709
$ chegada_prevista <dbl> 819, 830, 850, 1022, 837, 728, 854, 723
$ atraso_chegada   <dbl> 11, 20, 33, -18, -25, 12, 19, -14, -8,
$ companhia_aerea  <chr> "UA", "UA", "AA", "B6", "DL", "UA", "B6
$ voo              <dbl> 1545, 1714, 1141, 725, 461, 1696, 507,
```

Seleção de todas as colunas segundo uma função.

```
df_select <- df_voos |>
  select(where(is.character))
glimpse(df_select)
```

```
Rows: 336,776
Columns: 4
$ companhia_aerea <chr> "UA", "UA", "AA", "B6", "DL", "UA", "B6"
$ cauda           <chr> "N14228", "N24211", "N619AA", "N804JB",
$ origem          <chr> "EWR", "LGA", "JFK", "JFK", "LGA", "EWR"
$ destino         <chr> "IAH", "IAH", "MIA", "BQN", "ATL", "ORD"
```

Seleção de todas as colunas que começam com alguma *string*.

```
df_select <- dados_iris |>
  select(starts_with("largura"))
glimpse(df_select)
```

```
Rows: 150
Columns: 0
```

Seleção de todas as colunas que terminam com alguma *string*.

```
df_select <- df_voos |>
  select(ends_with("_chegada"))
glimpse(df_select)
```

```
Rows: 336,776
Columns: 2
$ horario_chegada <dbl> 830, 850, 923, 1004, 812, 740, 913, 709,
$ atraso_chegada  <dbl> 11, 20, 33, -18, -25, 12, 19, -14, -8, 8
```

Seleção de todas as colunas que contém alguma *string*.

```
df_select <- df_voos |>
  select(contains("chegada"))
glimpse(df_select)
```

```
Rows: 336,776
Columns: 3
$ horario_chegada  <dbl> 830, 850, 923, 1004, 812, 740, 913, 709
$ chegada_prevista <dbl> 819, 830, 850, 1022, 837, 728, 854, 723
$ atraso_chegada   <dbl> 11, 20, 33, -18, -25, 12, 19, -14, -8,
```

Seleção de todas as colunas em sequencia.

```
dados_billboard <- read_excel("dados/brutos/billboard_eua_2000.x
df_select <- dados_billboard |>
  select(num_range("semana_", 1:6))
glimpse(df_select)
```

```
Rows: 317
Columns: 6
$ semana_1 <dbl> 87, 91, 81, 76, 57, 51, 97, 84, 59, 76, 84, 57,
$ semana_2 <dbl> 82, 87, 70, 76, 34, 39, 97, 62, 53, 76, 84, 47,
$ semana_3 <dbl> 72, 92, 68, 72, 25, 34, 96, 51, 38, 74, 75, 45,
$ semana_4 <dbl> 77, NA, 67, 69, 17, 26, 95, 41, 28, 69, 73, 29,
$ semana_5 <dbl> 87, NA, 66, 67, 17, 26, 100, 38, 21, 68, 73, 23
$ semana_6 <dbl> 94, NA, 57, 65, 31, 19, NA, 35, 18, 67, 69, 18,
```

Transformações nos dados
rename()

Renome as colunas de um `data.frame`.

O padrão de renomeação é: `<nome novo> = <nome velho>`.

```
df_iris <- dados_iris |>
  rename(
    "sepala_comprimento" = "comprimento_sepala",
    "sepala_largura" = "largura_sepala",
    "petala_comprimento" = "comprimento_petala",
    "petala_largura" = "largura_petala"
  )
glimpse(df_iris)
```

```
Rows: 150
Columns: 5
$ sepala_comprimento <dbl> 5.1, 4.9, 4.7, 4.6, 5.0, 5.4, 4.6, 5.
$ sepala_largura     <dbl> 3.5, 3.0, 3.2, 3.1, 3.6, 3.9, 3.4, 3.
$ petala_comprimento <dbl> 1.4, 1.4, 1.3, 1.5, 1.4, 1.7, 1.4, 1.
$ petala_largura     <dbl> 0.2, 0.2, 0.2, 0.2, 0.2, 0.4, 0.3, 0.
$ especies           <chr> "setosa", "setosa", "setosa", "setosa
```

Transformações nos dados
`relocate()`

Move as colunas pelo `data.frame`. Por padrão, as colunas listas vão para a extrema esqueda do `data.frame`, mas pode usar os argumentos `.before` e `.after`:

- `.before`: número inteiro positivo (indicado a posição da coluna) ou o nome da coluna. As colunas serão incluídas a esquerda.
- `.after`: número inteiro positivo (indicado a posição da coluna) ou o nome da coluna. As colunas serão incluídas a direita.

```r
dados_mtcarros <- dados_mtcarros |>
  relocate(marchas, carburadores, .before = "cilindros")
glimpse(dados_mtcarros)
```

```
Rows: 32
Columns: 11
$ milhas_por_galao <dbl> 21.0, 21.0, 22.8, 21.4, 18.7, 18.1, 14.
$ marchas          <dbl> 4, 4, 4, 3, 3, 3, 3, 4, 4, 4, 4, 3, 3,
$ carburadores     <dbl> 4, 4, 1, 1, 2, 1, 4, 2, 2, 4, 4, 3, 3,
$ cilindros        <dbl> 6, 6, 4, 6, 8, 6, 8, 4, 4, 6, 6, 8, 8,
$ cilindrada       <dbl> 160.0, 160.0, 108.0, 258.0, 360.0, 225.
$ cavalos_forca    <dbl> 110, 110, 93, 110, 175, 105, 245, 62, 9
$ eixo             <dbl> 3.90, 3.90, 3.85, 3.08, 3.15, 2.76, 3.2
$ peso             <dbl> 2.620, 2.875, 2.320, 3.215, 3.440, 3.46
$ velocidade       <dbl> 16.46, 17.02, 18.61, 19.44, 17.02, 20.2
$ forma            <dbl> 0, 0, 1, 1, 0, 1, 0, 1, 1, 1, 1, 0, 0,
$ transmissao      <dbl> 1, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0,
```

Transformações nos dados
Exercício

Para o conjunto de dados `amostra_enem_salvador.xlsx`, realize as seguinte operações:

- transforme a variável `tp_cor_raca` em fator, e agrupe os valores `parda` e `preta` em `negra`;
- selecione as colunas: `tp_cor_raca`, `tp_escola` e `nu_nota_mt`;
- renomeie as colunas da seguinte forma:
  - `tp_cor_raca` por `raca`;
  - `tp_escola` por `tipo_escola`;
  - `nu_nota_mt` por `nota_matematica`;
- coloque `tipo_escola` como a primeira coluna.

grupos

- `group_by`: transforma um `tibble` em um `tibble` agrupado por uma ou mais colunas. Todas as operações serão realizadas por este agrupamento;
- `slice_*` (* pode ser `min`, `max`, `sample`, `tail`, e `head`): extrai uma ou algumas linhas de cada grupo;
- `summarize`: calcula medidas de resumo por grupos;
- `ungroup`: remove o agrupamento.

Transformações nos dados
group_by()

Prepara um conjunto de dados para realizar operações em grupos (usando a função summarise).

```
dados_mtcarros_grupos <- group_by(dados_mtcarros, marchas, carburadores)
glimpse(dados_mtcarros_grupos)
```

```
Rows: 32
Columns: 11
Groups: marchas, carburadores [11]
$ milhas_por_galao <dbl> 21.0, 21.0, 22.8, 21.4, 18.7, 18.1, 14.3, 24.4, 22.8,~
$ marchas          <dbl> 4, 4, 4, 3, 3, 3, 3, 4, 4, 4, 4, 3, 3, 3, 3, 3, 3, 4,~
$ carburadores     <dbl> 4, 4, 1, 1, 2, 1, 4, 2, 2, 4, 4, 3, 3, 3, 4, 4, 4, 1,~
$ cilindros        <dbl> 6, 6, 4, 6, 8, 6, 8, 4, 4, 6, 6, 8, 8, 8, 8, 8, 8, 4,~
$ cilindrada       <dbl> 160.0, 160.0, 108.0, 258.0, 360.0, 225.0, 360.0, 146.~
$ cavalos_forca    <dbl> 110, 110, 93, 110, 175, 105, 245, 62, 95, 123, 123, 1~
$ eixo             <dbl> 3.90, 3.90, 3.85, 3.08, 3.15, 2.76, 3.21, 3.69, 3.92,~
$ peso             <dbl> 2.620, 2.875, 2.320, 3.215, 3.440, 3.460, 3.570, 3.19~
$ velocidade       <dbl> 16.46, 17.02, 18.61, 19.44, 17.02, 20.22, 15.84, 20.0~
$ forma            <dbl> 0, 0, 1, 1, 0, 1, 0, 1, 1, 1, 1, 0, 0, 0, 0, 0, 0, 1,~
$ transmissao      <dbl> 1, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1,~
```

Transformações nos dados
`slice_*()`

Pega parte do `data.frame` respeitamento o agrupamento estabelecido por `group_by`.

- `df |> slice_head(n = 1)` pega as `n` primeiras linhas de cada grupo.
- `df |> slice_tail(n = 1)` pega as `n` últimas linhas de cada grupo.
- `df |> slice_min(x, n = 1)` pega as linhas com os menores valores de `x` em cada grupo.
- `df |> slice_max(x, n = 1)` pega as linhas com os maiores valores de `x` em cada grupo.
- `df |> slice_sample(n = 1)` pega aleatoriamente `n` linhas de cada grupo.

```r
dados_iris |>
  group_by(especies) |>
  slice_sample(n = 2)
```

```
# A tibble: 6 x 5
# Groups:   especies [3]
  comprimento_sepala largura_sepala comprimento_petala largura_p
               <dbl>           <dbl>              <dbl>
1                5.4             3.4                1.5
2                5.1             3.5                1.4
3                5.9             3                  4.2
4                5.7             2.8                4.1
5                6.3             3.4                5.6
6                6               2.2                5
```

summarise()

Calcula medidas de resumo por cada grupo.

Caso 1: apenas uma variável

Retorna um `data.frame` sem agrupamento.

```
df_voos |>
  group_by(mes) |>
  summarise(freq = n())
```

```
# A tibble: 12 x 2
     mes  freq
   <dbl> <int>
 1     1 27004
 2     2 24951
 3     3 28834
 4     4 28330
 5     5 28796
 6     6 28243
 7     7 29425
 8     8 29327
 9     9 27574
10    10 28889
11    11 27268
12    12 28135
```

Caso 2: duas ou mais variáveis

Neste caso, `summarise` retorna um `data.frame` com agrupamentos que são controlados pelo argumento `.groups`:

- se `.groups = "drop_last"`: o agrupamento da última variável é retirado. Este é o comportamento padrão (para compatibilidade com versões antigas do tidyverse).
- se `.groups = "keep"`: os agrupamentos de todas as variáveis são mantidas.
- se `.groups = "drop"`: os agrupamentos de todas as variáveis são retiradas. (Geralmente, usamos este).
- se `.groups = "rowwise"`: os agrupamentos são mantidos para que linha tenha o seu próprio grupo.

Usando .groups = "drop_last".

```
dados_mtcarros |>
  group_by(marchas, forma) |>
  summarise(peso_medio = mean(peso, na.rm = TRUE))
```

```
# A tibble: 6 x 3
# Groups:   marchas [3]
  marchas forma peso_medio
    <dbl> <dbl>      <dbl>
1       3     0       4.10
2       3     1       3.05
3       4     0       2.75
4       4     1       2.59
5       5     0       2.91
6       5     1       1.51
```

Usando .groups = "keep".

```
dados_mtcarros |>
  group_by(marchas, forma) |>
  summarise(peso_medio = mean(peso, na.rm = TRUE),
            .groups = "keep")
```

```
# A tibble: 6 x 3
# Groups:   marchas, forma [6]
  marchas forma peso_medio
    <dbl> <dbl>      <dbl>
1       3     0       4.10
2       3     1       3.05
3       4     0       2.75
4       4     1       2.59
5       5     0       2.91
6       5     1       1.51
```

Usando .groups = "drop".

```
dados_mtcarros |>
  group_by(marchas, forma) |>
  summarise(peso_medio = mean(peso, na.rm = TRUE),
            .groups = "drop")
```

```
# A tibble: 6 x 3
  marchas forma peso_medio
    <dbl> <dbl>      <dbl>
1       3     0       4.10
2       3     1       3.05
3       4     0       2.75
4       4     1       2.59
5       5     0       2.91
6       5     1       1.51
```

Transformações nos dados
Exercício

Para o conjunto de dados `amostra_enem_salvador.xlsx`, realize as seguinte operações:

- selecione as colunas `tp_cor_raca`, `tp_escola` e `nu_nota_mt`;
- agrupe o conjunto de dados por `tp_cor_raca` e `tp_escola`;
- pegue dois elementos de cada grupo;
- conte o número de pessoas em cada grupo e calcule a mediana.

União de **conjunto de dados**.

- chaves (primárias e estrangeiras);
- adicionando novas colunas de outros conjuntos de dados: `left_join()`, `inner_join()`, `right_join()`, `full_join()`, `semi_join()`, e `anti_join()`;
- filtragem: `semi_join()` e `anti_join()`.

chaves

chave primária : variável ou conjunto de variáveis (colunas) determinam unicamente uma observação (uma linha);

chave estrangeira : variável ou conjunto de variáveis (colunas) que corresponde a uma chave primária de outro conjunto de dados;

Geralmente **chaves primárias** e **chaves estrangeiras** têm o mesmo nome (para facilitar nossa vida);

Verifique se cada valor da chave idenfica no máximo uma observação.

Transformações nos dados
`*_join()`

- `left_join(x, y, join_by(key_x == key_y))`: mantêm todas as linhas de `x` (com as colunas de `y`);
- `inner_join(x, y, join_by(key_x == key_y))`: mantêm todas as linhas que estão em `x` e `y` (com as linhas de `y`);
- `right_join(x, y, join_by(key_x == key_y))`: mantêm todas as linhas de `y` (com as colunas de `x`);
- `full_join(x, y, join_by(key_x == key_y))`: mantêm todas as linhas de `x` e `y` (com as colunas de `x` e `y`);
- `semi_join(x, y, join_by(key_x == key_y))`: mantêm as linhas de `x` que estão em `y` (mantem as apenas as colunas de `x`);
- `anti_join(x, y, join_by(key_x == key_y))`: mantêm as linhas de `x` que **não** estão em `y` (mantem as apenas as colunas de `x`).

Figura 1: Ilustração de `left_join`, `right_join`, `inner_join` e `full_join`.

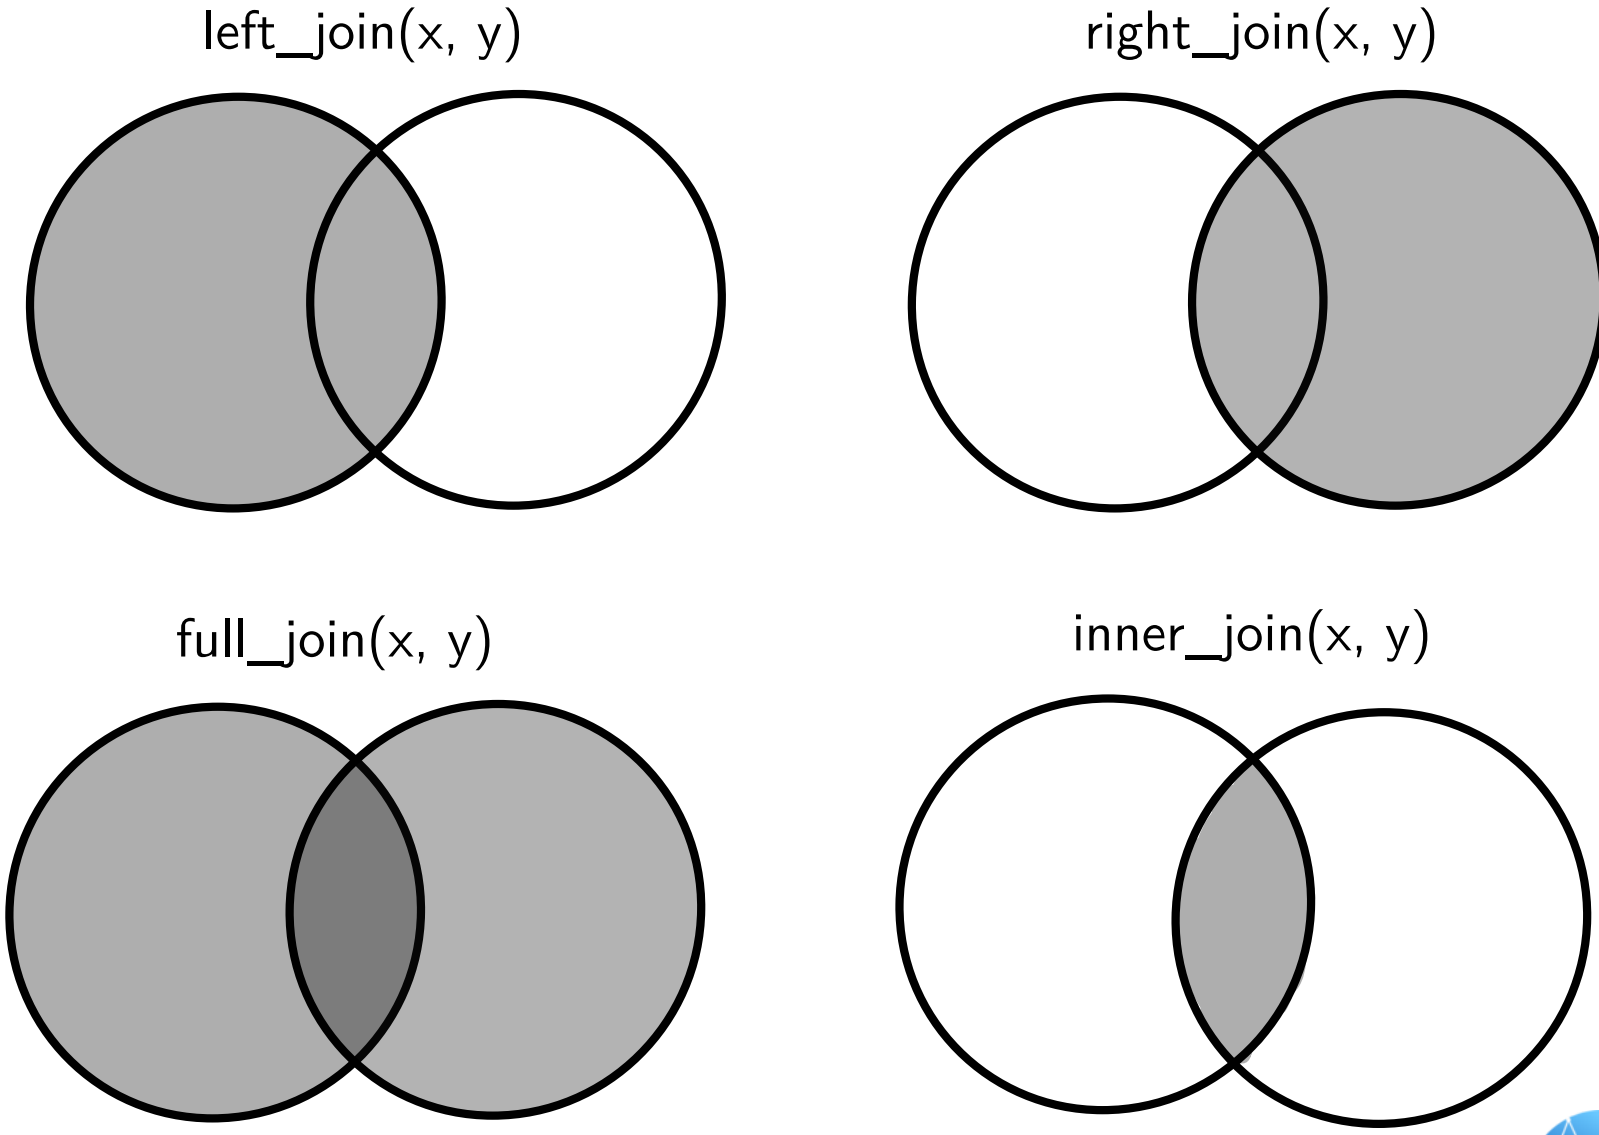

Transformações nos dados
`*_join()`

Em `voos.xlsx` temos o código da companhia aérea, mas não tem o nome.

O nome da companhia aérea está na coluna `nome` em `companhia_aerea.xlsx`.

```
df_companhias_aereas <- read_excel("dados/brutos/companhias_aereas.xlsx")
df_voos2 <- df_voos |>
  left_join(df_companhias_aereas, join_by(companhia_aerea == companhia_aerea))
glimpse(df_voos2)
```

```
Rows: 336,776
Columns: 21
$ velocidade       <dbl> 6.167401, 6.237885, 6.806250, 8.612022, 6.568966, 4.7~
$ ano              <dbl> 2013, 2013, 2013, 2013, 2013, 2013, 2013, 2013, 2013,~
$ mes              <dbl> 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1,~
$ dia              <dbl> 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1,~
$ horario_saida    <dbl> 517, 533, 542, 544, 554, 554, 555, 557, 557, 558, 558~
$ saida_programada <dbl> 515, 529, 540, 545, 600, 558, 600, 600, 600, 600, 600~
$ atraso_saida     <dbl> 2, 4, 2, -1, -6, -4, -5, -3, -3, -2, -2, -2, -2, -2, ~
$ horario_chegada  <dbl> 830, 850, 923, 1004, 812, 740, 913, 709, 838, 753, 84~
$ chegada_prevista <dbl> 819, 830, 850, 1022, 837, 728, 854, 723, 846, 745, 85~
$ atraso_chegada   <dbl> 11, 20, 33, -18, -25, 12, 19, -14, -8, 8, -2, -3, 7, ~
$ companhia_aerea  <chr> "UA", "UA", "AA", "B6", "DL", "UA", "B6", "EV", "B6",~
$ voo              <dbl> 1545, 1714, 1141, 725, 461, 1696, 507, 5708, 79, 301,~
$ cauda            <chr> "N14228", "N24211", "N619AA", "N804JB", "N668DN", "N3~
$ origem           <chr> "EWR", "LGA", "JFK", "JFK", "LGA", "EWR", "EWR", "LGA~
$ destino          <chr> "IAH", "IAH", "MIA", "BQN", "ATL", "ORD", "FLL", "IAD~
$ tempo_voo        <dbl> 227, 227, 160, 183, 116, 150, 158, 53, 140, 138, 149,~
$ distancia        <dbl> 1400, 1416, 1089, 1576, 762, 719, 1065, 229, 944, 733~
$ hora             <dbl> 5, 5, 5, 5, 6, 5, 6, 6, 6, 6, 6, 6, 6, 6, 6, 5, 6, 6,~
$ minuto           <dbl> 15, 29, 40, 45, 0, 58, 0, 0, 0, 0, 0, 0, 0, 0, 0, 59,~
$ data_hora        <dttm> 2013-01-01 10:00:00, 2013-01-01 10:00:00, 2013-01-01~
$ nome             <chr> "United Air Lines Inc.", "United Air Lines Inc.", "Am~
```

Transformações nos dados
Exercício

Adicione as condições climáticas (`clima.csv`) a cada voo no conjunto de dados `voos.xlsx`. Use como chave `data_hora` e `origem`.
(Dica: use `left_join`).

Depois selecione os voos de algumas companhias aéreas que estão em `companhias_especiais.csv`. Use como chave `companhia_aerea`.
(Dica: use `semi_join`).