

Manipulação de dados com o dplyr

Prof. Walmes Zeviani

walmes@ufpr.br

Laboratório de Estatística e Geoinformação
Departamento de Estatística
Universidade Federal do Paraná

Um overview do dplyr

Motivação

- ▶ Depois dos dados arrumados, é a hora começar conhecê-los!
- ▶ Começa a fase de **análise exploratória de dados** (AED).
- ▶ Os dados são explorados para:
 - ▶ Conhecer as (propriedades das) variáveis.
 - ▶ Determinar medidas descritivas.
 - ▶ Comparar grupos.
 - ▶ Quantificar relações entre variáveis.
 - ▶ Extrair padrões.
 - ▶ Detectar ameaças e corrigir problemas.
- ▶ AED envolve inúmeras operações.
- ▶ É preciso conhecê-las e ser criativo para aplicar da melhor forma.

Detalhes do dplyr

- ▶ O dplyr é a **gramática** para manipulação de dados.
- ▶ Tem um conjunto **consistente** de verbos para atuar sobre tabelas.
 - ▶ Verbos: `mutate()`, `select()`, `filter()`, `arrange()`, `summarise()`, `slice()`, `rename()`, etc.
 - ▶ Sufixos: `_at()`, `_if()`, `_all()`, etc.
 - ▶ Agrupamento: `group_by()` e `ungroup()`.
 - ▶ Junções: `inner_join()`, `full_join()`, `left_join()` e `right_join()`.
 - ▶ Funções resumo: `n()`, `n_distinct()`, `first()`, `last()`, `nth()`, etc.
 - ▶ E muito mais no cartão de referência: <https://github.com/rstudio/cheatsheets/raw/master/data-transformation.pdf>.
- ▶ Documentação:
 - ▶ <https://dplyr.tidyverse.org/>.
 - ▶ <https://r4ds.had.co.nz relational-data.html>.
 - ▶ <https://cran.r-project.org/package=dplyr>

A ficha técnica

dplyr: A Grammar of Data Manipulation

A fast, consistent tool for working with data frame like objects, both in memory and out of memory.

Version:	0.8.0.1
Depends:	R (\geq 3.1.2)
Imports:	assertthat (\geq 0.2.0), glue (\geq 1.1.1), magrittr (\geq 1.5), methods , pkgconfig (\geq 2.0.1), R6 (\geq 2.2.2), Rcpp (\geq 1.0.0), rlang (\geq 0.3.0), tibble (\geq 2.0.0), tidyselect (\geq 0.2.5), utils
LinkingTo:	BH (\geq 1.58.0-1), plogr (\geq 0.1.10), Rcpp (\geq 1.0.0)
Suggests:	bit64 (\geq 0.9.7), callr (\geq 3.1.1), covr (\geq 3.0.1), DBI (\geq 0.7.14), dbplyr (\geq 1.2.0), dtplyr (\geq 0.0.2), ggplot2 (\geq 2.2.1), hms (\geq 0.4.1), knitr (\geq 1.19), Lahman (\geq 3.0-1), lubridate (\geq 1.7.4), MASS , mgcv (\geq 1.8.23), microbenchmark (\geq 1.4.4), nycflights13 (\geq 0.2.2), rmarkdown (\geq 1.8), RMySQL (\geq 0.10.13), RPostgreSQL (\geq 0.6.2), RSQlite (\geq 2.0), testthat (\geq 2.0.0), withr (\geq 2.1.1), broom (\geq 0.5.1), purrr (\geq 0.3.0), readr (\geq 1.3.1), crayon (\geq 1.3.4)
Published:	2019-02-15
Author:	Hadley Wickham [aut, cre], Romain François [aut], Lionel Henry [aut], Kirill Müller [aut], RStudio [cph, fnd]
Maintainer:	Hadley Wickham <hadley at rstudio.com>
BugReports:	https://github.com/tidyverse/dplyr/issues
License:	MIT + file LICENSE
URL:	http://dplyr.tidyverse.org , https://github.com/tidyverse/dplyr
NeedsCompilation:	yes
Materials:	README NEWS
In views:	Databases , ModelDeployment
CRAN checks:	dplyr results

Figura 1. Ficha técnica do dplyr.

Data Transformation with dplyr :: CHEAT SHEET



dplyr functions work with pipes and expect **tidy data**. In tidy data:



Each variable is in its own column

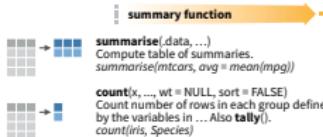
Each observation, or case, is in its own row



x %>% f(y) becomes f(x, y)

Summarise Cases

These apply **summary functions** to columns to create a new table of summary statistics. Summary functions take vectors as input and return one value (see back).

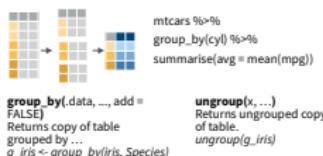


VARIATIONS

summarise_all() - Apply funs to every column.
summarise_at() - Apply funs to specific columns.
summarise_if() - Apply funs to all cols of one type.

Group Cases

Use **group_by()** to create a "grouped" copy of a table. dplyr functions will manipulate each "group" separately and then combine the results.



Manipulate Cases

EXTRACT CASES

Row functions return a subset of rows as a new table.

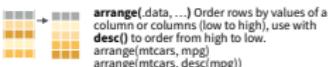


Logical and boolean operators to use with filter()

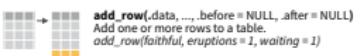
< <= is.na() %in% | xor()
> >= !is.na() ! &

See ?base:::logic and ?Comparison for help.

ARRANGE CASES



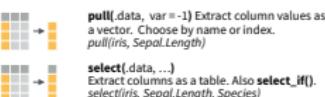
ADD CASES



Manipulate Variables

EXTRACT VARIABLES

Column functions return a set of columns as a new vector or table.



Use these helpers with **select()**, e.g. **select(iris, starts_with("Sepal"))**

contains(match) **num_range(prefix, range)** ;, e.g. **mpg:cyl**
ends_with(match) **one_of(...)** ;, e.g., **-Species**
matches(match) **starts_with(match)**

MAKE NEW VARIABLES

These apply **vectorized functions** to columns. Vectorized funs take vectors as input and return vectors of the same length as output (see back).

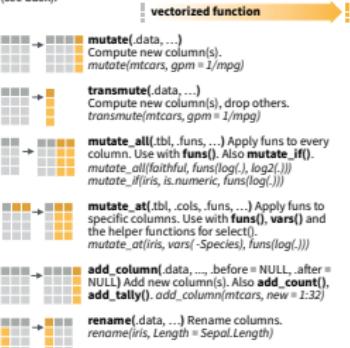


Figura 2. Cartão de referência de operações em dados com tabulares com dplyr.



Vector Functions

TO USE WITH MUTATE ()

mutate() and **transmute()** apply vectorized functions to columns to create new columns. Vectorized functions take vectors as input and return vectors of the same length as output.

vectorized function

OFFSETS

dplyr::lag() - Offset elements by 1
dplyr::lead() - Offset elements by -1

CUMULATIVE AGGREGATES

dplyr::cumall() - Cumulative all()
dplyr::cumany() - Cumulative any()
cummax() - Cumulative max()
dplyr::cummean() - Cumulative mean()
cummin() - Cumulative min()
cumprod() - Cumulative prod()
cumsum() - Cumulative sum()

RANKINGS

dplyr::cume_dist() - Proportion of all values <=
dplyr::dense_rank() - rank with ties = min, no gaps
dplyr::min_rank() - rank with ties = min
dplyr::ntile() - bins into n bins
dplyr::percent_rank() - min_rank scaled to [0,1]
dplyr::row_number() - rank with ties = "first"

MATH

* - ^ - / - ^%/% - %%% - arithmetic ops
log(), log2(), log10() - logs
<->, >->, ><->, == - logical comparisons
dplyr::between() - x <= left & x <= right
dplyr::near() - safe == for floating point numbers

MISC

dplyr::case_when() - multi-case if...else()
dplyr::coalesce() - first non-NA values by element across a set of vectors
dplyr::if_else() - element-wise if() + else()
dplyr::na_if() - replace specific values with NA
max() - element-wise max()
pmin() - element-wise min()
dplyr::recode() - Vectorized switch()
dplyr::recode_factor() - Vectorized switch() for factors

Summary Functions

TO USE WITH SUMMARISE ()

summarise() applies summary functions to columns to create a new table. Summary functions take vectors as input and return single values as output.

summary function

COUNTS

dplyr::n() - number of values/rows
dplyr::n_distinct() - # of uniques
sum(is.na()) - # of non-NAs

LOCATION

mean() - mean, also **mean(is.na())**
median() - median

LOGICALS

mean() - Proportion of TRUE's
sum() - # of TRUE's

POSITION/ORDER

dplyr::first() - first value
dplyr::last() - last value
dplyr::nth() - value in nth location of vector

RANK

quantile() - nth quantile
min() - minimum value
max() - maximum value

SPREAD

IQR() - Inter-Quartile Range
mad() - median absolute deviation
sd() - standard deviation
var() - variance

Row Names

Tidy data does not use rownames, which store a variable outside of the columns. To work with the rownames, first move them into a column.

rownames_to_column()
Move row names into col.
a <- rownames_to_column(iris, var = "C")

column_to_rownames()
Move col in row names.
column_to_rownames(a, var = "C")

Also has **rownames()**, **remove_rownames()**

Combine Tables

COMBINE VARIABLES

x y

+ =

Use **bind_cols()** to paste tables beside each other as they are.

bind_cols(...) Returns tables placed side by side as a single table.
BE SURE THAT ROWS ALIGN.

Use a "Mutating Join" to join one table to columns from another, matching values with the rows that they correspond to. Each join retains a different combination of values from the tables.

left_join(x, y, by = NULL,
copy = FALSE, suffix = c("x", "y", ...))
Join matching values from y to x.

right_join(x, y, by = NULL, copy =
FALSE, suffix = c("x", "y", ...))
Join matching values from x to y.

inner_join(x, y, by = NULL, copy =
FALSE, suffix = c("x", "y", ...))
Join data. Retain only rows with matches.

full_join(x, y, by = NULL,
copy = FALSE, suffix = c("x", "y", ...))
Join data. Retain all values, all rows.

Use **by = c("col1", "col2", ...)** to specify one or more common columns to match on.
left_join(x, y, by = "C")

Use a named vector, **by = c("col1" = "col2")**, to match on columns that have different names in each table.
left_join(x, y, by = "C" = "D")

Use **suffix** to specify the suffix to give to unmatched columns that have the same name in both tables.
left_join(x, y, by = c("C" = "D"), suffix = c("1", "2"))

COMBINE CASES

x y

+ =

Use **bind_rows()** to paste tables below each other as they are.

bind_rows(..., id = NULL)
Returns tables one on top of the other as a single table. Set .id to a column name to add a column of the original table names (as pictured)

intersect(x, y, ...)
Rows that appear in both x and y.

setdiff(x, y, ...)
Rows that appear in x but not y.

union(x, y, ...)
(Duplicates removed). union_all()
keeps duplicates.

Use **setequal()** to test whether two data sets contain the exact same rows (in any order).

EXTRACT ROWS

x y

+ =

Use a "Filtering Join" to filter one table against the rows of another.

semi_join(x, y, by = NULL, ...)
Return rows of x that have a match in y.
USEFUL TO SEE WHAT WILL BE JOINED.

anti_join(x, y, by = NULL, ...)
Return rows of x that do not have a match in y. USEFUL TO SEE WHAT WILL NOT BE JOINED.



RStudio® is a trademark of RStudio, Inc. • CC BY SA RStudio • info@rstudio.com • 844-448-1212 • rstudio.com • Learn more with browseVignettes(package = c("dplyr", "tibble")) • dplyr 0.7.0 • tibble 1.2.0 • Updated: 2017-03

Figura 3. Cartão de referência de operações em dados com tabulares com dplyr.

Ordenação

Ordenação ascendente

```
library(tidyverse)

tb <- tibble(x = 1:4,
             y = c(4, 7, 1, 3),
             z = c(10, 10, 22, 22),
             k = c(TRUE, FALSE, FALSE, TRUE),
             u = c("A", "B", "A", "B"))

tb %>%
  arrange(z, y)
```

```
## # A tibble: 4 x 5
##       x     y     z     k     u
##   <int> <dbl> <dbl> <lgl> <chr>
## 1     1     4    10  TRUE  A
## 2     2     7    10 FALSE B
## 3     3     1    22 FALSE A
## 4     4     3    22  TRUE  B
```

Ordenação descendente

```
tb %>%
  arrange(desc(z), -y)
```

```
## # A tibble: 4 x 5
##       x     y     z   k     u
##   <int> <dbl> <dbl> <lgl> <chr>
## 1     4     3    22 TRUE  B
## 2     3     1    22 FALSE A
## 3     2     7    10 FALSE B
## 4     1     4    10 TRUE  A
```

1

2

Seleções

Filtro de linhas

```
tb %>%
  filter(x > 2 | u == "A")  
  
## # A tibble: 3 x 5
##       x     y     z   k     u
##   <int> <dbl> <dbl> <lgl> <chr>
## 1     1     4    10 TRUE  A
## 2     3     1    22 FALSE A
## 3     4     3    22 TRUE  B
```

1

2

Fatiar linhas

```
tb %>% slice(1:3)
```

```
## # A tibble: 3 x 5
##       x     y     z   k     u
##   <int> <dbl> <dbl> <lgl> <chr>
## 1     1     4    10 TRUE  A
## 2     2     7    10 FALSE B
## 3     3     1    22 FALSE A
```

1

```
tb %>% slice(-(3:5))
```

```
## # A tibble: 2 x 5
##       x     y     z   k     u
##   <int> <dbl> <dbl> <lgl> <chr>
## 1     1     4    10 TRUE  A
## 2     2     7    10 FALSE B
```

1

Sortear linhas

```
tb %>% sample_n(size = 3)
```

```
## # A tibble: 3 x 5
##   x     y     z k     u
##   <int> <dbl> <dbl> <lgl> <chr>
## 1 1     4     10 TRUE  A
## 2 4     3     22 TRUE  B
## 3 3     1     22 FALSE A
```

1

```
tb %>% sample_frac(size = 0.5)
```

```
## # A tibble: 2 x 5
##   x     y     z k     u
##   <int> <dbl> <dbl> <lgl> <chr>
## 1 4     3     22 TRUE  B
## 2 3     1     22 FALSE A
```

1

Seleção de variáveis por listagem

```
tb %>% select(x, y) # Inclusão.
```

```
## # A tibble: 4 x 2
##       x     y
##   <int> <dbl>
## 1     1     4
## 2     2     7
## 3     3     1
## 4     4     3
```

```
tb %>% select(-z) # Exclusão.
```

```
## # A tibble: 4 x 4
##       x     y     k     u
##   <int> <dbl> <lgl> <chr>
## 1     1     4 TRUE  A
## 2     2     7 FALSE B
## 3     3     1 FALSE A
## 4     4     3 TRUE  B
```

```
tb %>% select(y:k) # Intervalo.
```

```
## # A tibble: 4 x 3
##       y     z     k
##   <dbl> <dbl> <lgl>
## 1     4    10 TRUE
## 2     7    10 FALSE
```

Seleção por posição

```
tb %>% select(3, 2, 1)
```

```
## # A tibble: 4 x 3
##       z     y     x
##   <dbl> <dbl> <int>
## 1    10     4     1
## 2    10     7     2
## 3    22     1     3
## 4    22     3     4
```

1

```
tb %>% select(-(1:2))
```

```
## # A tibble: 4 x 3
##       z     k     u
##   <dbl> <lgl> <chr>
## 1    10 TRUE  A
## 2    10 FALSE B
## 3    22 FALSE A
## 4    22 TRUE  B
```

1

Seleção de variáveis por condição

```
tb %>% select_if(is.numeric)
```

```
## # A tibble: 4 x 3
##       x     y     z
##   <int> <dbl> <dbl>
## 1     1     4    10
## 2     2     7    10
## 3     3     1    22
## 4     4     3    22
```

1

```
tb %>% select_if(negate(is.numeric))
```

```
## # A tibble: 4 x 2
##       k     u
##   <lgl> <chr>
## 1 TRUE  A
## 2 FALSE B
## 3 FALSE A
## 4 TRUE  B
```

1

Transformações

Modificar uma variável

```
tb %>%
  mutate(x = x * 2,
        u = as_factor(u))
```

```
## # A tibble: 4 x 5
##       x     y     z     k     u
##   <dbl> <dbl> <dbl> <lgl> <fct>
## 1     2     4    10 TRUE  A
## 2     4     7    10 FALSE B
## 3     6     1    22 FALSE A
## 4     8     3    22 TRUE  B
```

1
2
3

Criar variáveis uma variável

```
tb %>%
  mutate(v = y * z^(x/4))
```

```
## # A tibble: 4 x 6
##       x     y     z     k     u     v
##   <int> <dbl> <dbl> <lgl> <chr> <dbl>
## 1     1     4     10 TRUE  A     7.11
## 2     2     7     10 FALSE B    22.1
## 3     3     1     22 FALSE A    10.2
## 4     4     3     22 TRUE  B    66
```

Estatísticas resumo

Medidas resumo gerais

```
tb %>%
  summarise(x_mean = mean(x),
            y_median = median(y))

## # A tibble: 1 x 2
##   x_mean y_median
##     <dbl>     <dbl>
## 1      2.5       3.5
```

```
tb %>%
  summarise_if(.predicate = is.numeric, .funs = mean)

## # A tibble: 1 x 3
##   x     y     z
##   <dbl> <dbl> <dbl>
## 1  2.5  3.75  16
```

```
# tb %>% summarise_at(.vars = c("x", "y"), .funs = mean)
# tb %>% summarise_at(.vars = 1:3, .funs = mean)
tb %>%
  summarise_at(.vars = vars(x:z), .funs = mean)

## # A tibble: 1 x 3
##   x     y     z
##   <dbl> <dbl> <dbl>
## 1  2.5  3.75  16
```

Medidas resumo vetoriais

```
# Funções que retornam vetores.  
# range(tb$x)  
# fivenum(tb$x)  
  
tb %>%  
  summarise(x = list(range(x)),  
            y = list(range(y))) %>%  
  unnest()
```

```
## # A tibble: 2 x 2  
##       x     y  
##   <int> <dbl>  
## 1     1     1  
## 2     4     7
```

```
tb %>%  
  do(data_frame(x = range(.x),  
                y = range(.y)))
```

```
## # A tibble: 2 x 2  
##       x     y  
##   <int> <dbl>  
## 1     1     1  
## 2     4     7
```

```
tb %>%  
  summarise_if(is.numeric, function(s) list(range(s))) %>%
```

Descrição global

[https://dabblingwithdata.wordpress.com/2018/01/02/
my-favourite-r-package-for-summarising-data/](https://dabblingwithdata.wordpress.com/2018/01/02/my-favourite-r-package-for-summarising-data/)

```
Hmisc::describe(iris)
```

1

```
psych::describe(iris)
```

2

```
skimr::skim(iris)
```

3

```
brotools::describe(iris)
```

1

```
summarytools::descr(iris)
```

2

```
summarytools::dfSummary(iris)
```

3

Agregações

Agrupando por variáveis estratificadoras

```
tb %>%  
  count(u)
```

1
2

```
## # A tibble: 2 x 2  
##   u     n  
##   <chr> <int>  
## 1 A         2  
## 2 B         2
```

```
tb %>%  
  group_by(u) %>%  
  summarise(x_mean = mean(x),  
            y_range = max(y) - min(y),  
            z_desv = sd(z))
```

1
2
3
4
5

```
## # A tibble: 2 x 4  
##   u     x_mean y_range z_desv  
##   <chr>    <dbl>    <dbl>    <dbl>  
## 1 A         2        3      8.49  
## 2 B         3        4      8.49
```

```
tb %>%  
  group_by(u) %>%  
  summarise_if(is.numeric, mean)
```

1
2
3

```
## # A tibble: 2 x 4  
##   u     x     v     z
```

Agrupando usando funções resumo vetoriais

```
tb %>%
  group_by(u) %>%
  summarise_if(is.numeric, funs(min, median, max))

## # A tibble: 2 x 10
##   u     x_min y_min z_min x_median y_median z_median x_max y_max z_max
##   <chr> <dbl> <dbl> <dbl>    <dbl>    <dbl>    <dbl> <dbl> <dbl> <dbl>
## 1 A        1     1    10        2      2.5     2.5    16     3     4    22
## 2 B        2     3    10        3      5       5       16     4     7    22
```

```
tb %>%
  group_by(u) %>%
  do(data_frame(stat = c("min", "q1", "median", "q3", "max"),
                x = fivenum(.x),
                y = fivenum(.y)))
```

```
## # A tibble: 10 x 4
## # Groups:   u [2]
##   u     stat     x     y
##   <chr> <chr> <dbl> <dbl>
## 1 A     min     1     1
## 2 A     q1      1     1
## 3 A     median  2     2.5
## 4 A     q3      3     4
## 5 A     max     3     4
## 6 B     min     2     3
## 7 B     q1      2     3
## 8 B     median  2     5
```

Junções

Interseção

```
tb1 <- tibble(aluno = c("Marcos", "Pedro", "Cintia", "Larissa", "Carla"), 1
               nota = c(10, 3, 6, 9, 10), 2
               faltas = c(3, 5, 6, 3, 0)) 3
tb2 <- tibble(paciente = c("Pedro", "Larissa", "Marcos", "Lucas"), 4
               consulta = c("2017-02-23", "2019-01-30", "2018-12-10", "2018-11-01"), 5
               exame = c("sangue", "urina", NA, NA)) 6
inner_join(tb1, tb2, by = c("aluno" = "paciente")) 7
8
```

```
## # A tibble: 3 x 5
##   aluno     nota faltas consulta     exame
##   <chr>    <dbl> <dbl> <chr>       <chr>
## 1 Marcos      10     3 2018-12-10 <NA>
## 2 Pedro        3     5 2017-02-23 sangue
## 3 Larissa      9     3 2019-01-30 urina
```

```
full_join(tb1, tb2, by = c("aluno" = "paciente"))
```

1

```
## # A tibble: 6 x 5
##   aluno    nota faltas consulta     exame
##   <chr>    <dbl> <dbl> <chr>      <chr>
## 1 Marcos     10     3 2018-12-10 <NA>
## 2 Pedro       3     5 2017-02-23 sangue
## 3 Cintia      6     6 <NA>        <NA>
## 4 Larissa     9     3 2019-01-30 urina
## 5 Carla       10    0 <NA>        <NA>
## 6 Lucas       NA    NA 2018-11-20 <NA>
```

Junções parciais

```
right_join(tb1, tb2, by = c("aluno" = "paciente"))
```

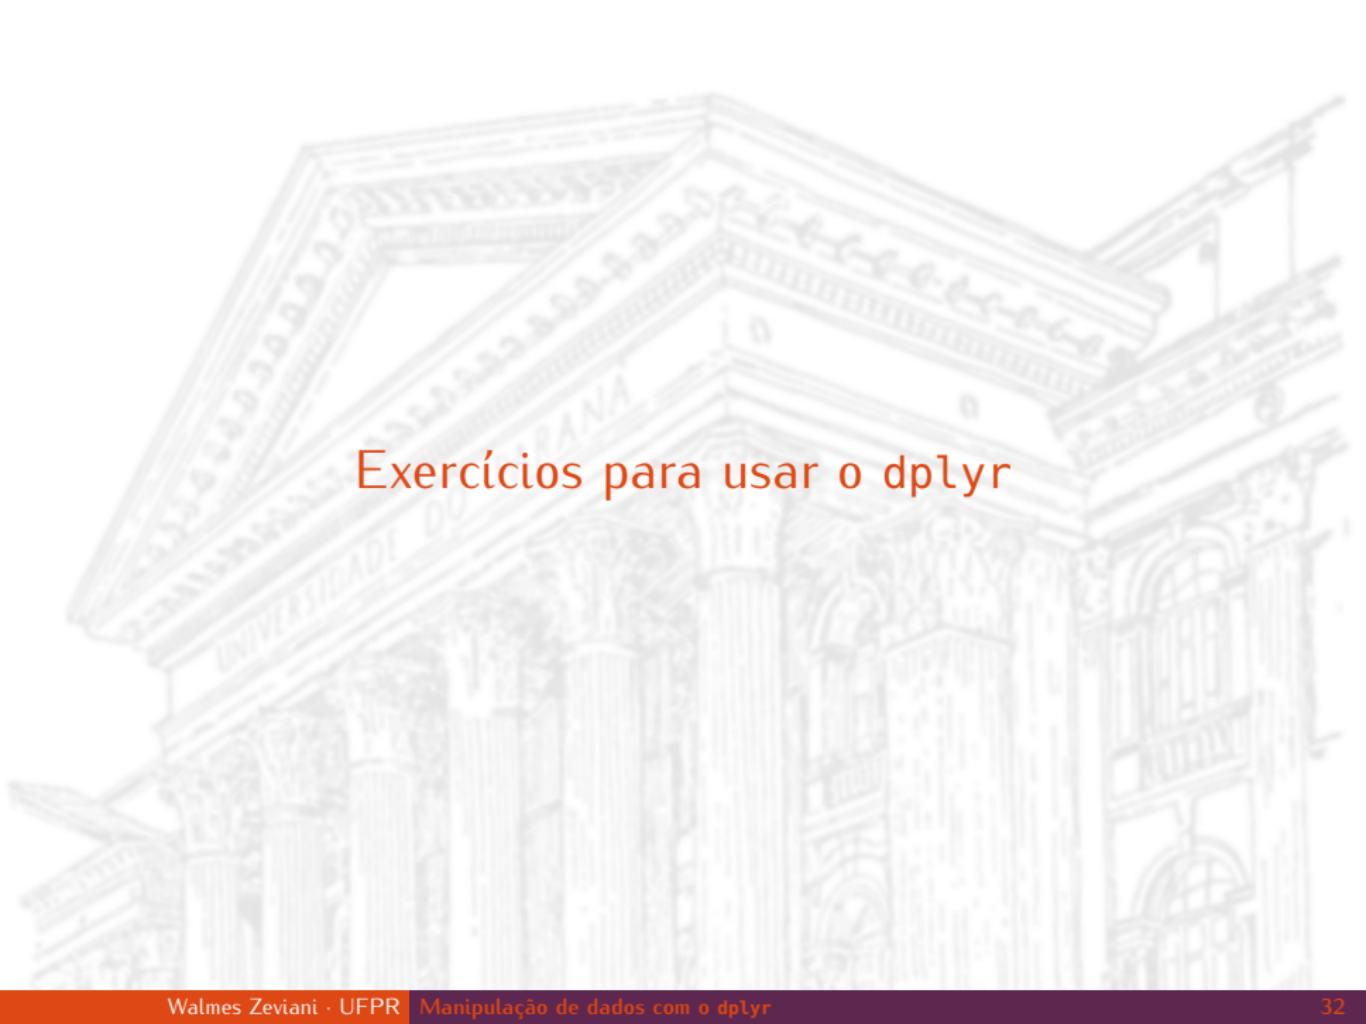
```
## # A tibble: 4 x 5
##   aluno    nota faltas consulta exame
##   <chr>    <dbl> <dbl> <chr>   <chr>
## 1 Pedro      3     5 2017-02-23 sangue
## 2 Larissa    9     3 2019-01-30 urina
## 3 Marcos     10    3 2018-12-10 <NA>
## 4 Lucas      NA    NA 2018-11-20 <NA>
```

1

```
left_join(tb1, tb2, by = c("aluno" = "paciente"))
```

```
## # A tibble: 5 x 5
##   aluno    nota faltas consulta exame
##   <chr>    <dbl> <dbl> <chr>   <chr>
## 1 Marcos    10     3 2018-12-10 <NA>
## 2 Pedro      3     5 2017-02-23 sangue
## 3 Cintia     6     6 <NA>       <NA>
## 4 Larissa    9     3 2019-01-30 urina
## 5 Carla     10     0 <NA>       <NA>
```

1

A faint, grayscale watermark-like image of a classical building's facade, featuring columns and architectural details, serves as the background for the slide.

Exercícios para usar o dplyr

Ninfas em soja

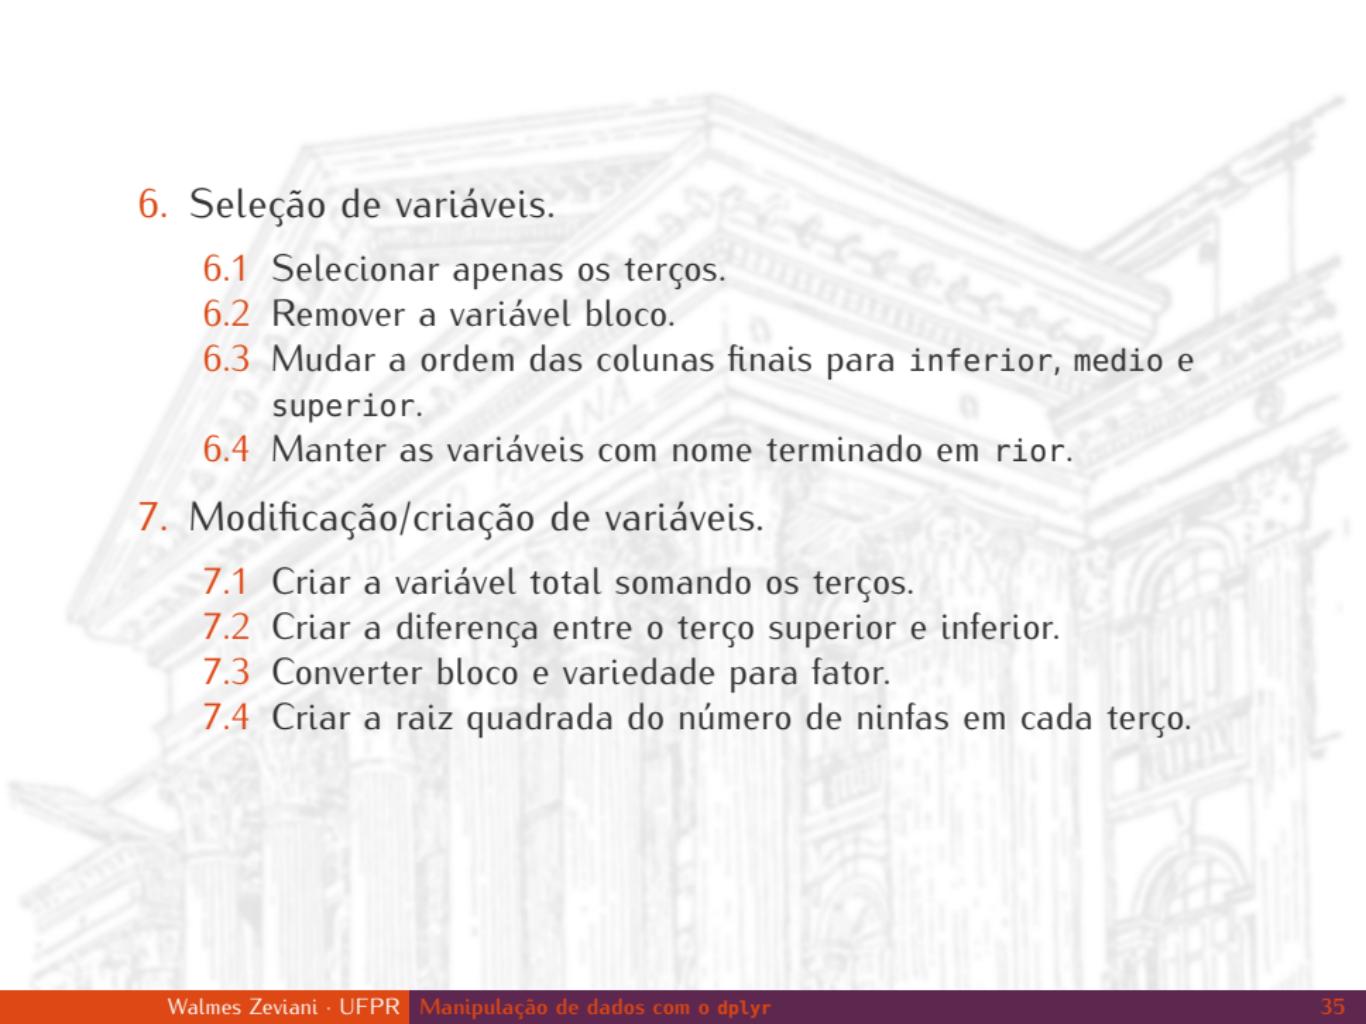
1. Ler os dados em <http://leg.ufpr.br/~walmes/data/ninfas.txt>.
2. Ordenação.
 - 2.1 Ordenar pelo valor do terço superior.
 - 2.2 Ordenar pelo valor do terço medio de forma descrescente.
 - 2.3 Ordenar pelas datas > variedade > bloco.
3. Filtros.
 - 3.1 Filtrar só para a variedade BRS 245 RR.
 - 3.2 Filtrar só para a variedade BRS 245 RR e EMBRAPA 48.
 - 3.3 Filtrar só para variedades diferentes de EMBRAPA 48.
 - 3.4 Filtrar quando superior com mais de 30 e inferior com mais de 20.
 - 3.5 Filtrar para medio entre 20 e 50.
 - 3.6 Filtrar para avaliações entre 2009-12-24 e 2010-01-11.
 - 3.7 Filtrar para a soma dos terços maior que 100.

4. Fatias.

- 4.1 As linhas 34, 74, 23 e 41.
- 4.2 As 10 primeiras linhas.
- 4.3 Da linha 50 até a 63.
- 4.4 As últimas 10 linhas.
- 4.5 Apenas a linhas com posição múltipla de 3.
- 4.6 Remover as 100 primeiras linhas.

5. Amostragem.

- 5.1 Uma amostra de 30 linhas.
- 5.2 Uma amostra de 30 linhas com reposição.
- 5.3 Uma amostra de 10% das linhas.
- 5.4 Pegar 20 registros com os maior número de ninfas no superior.



6. Seleção de variáveis.

- 6.1 Selecionar apenas os terços.
- 6.2 Remover a variável bloco.
- 6.3 Mudar a ordem das colunas finais para inferior, medio e superior.
- 6.4 Manter as variáveis com nome terminado em rior.

7. Modificação/criação de variáveis.

- 7.1 Criar a variável total somando os terços.
- 7.2 Criar a diferença entre o terço superior e inferior.
- 7.3 Converter bloco e variedade para fator.
- 7.4 Criar a raiz quadrada do número de ninfas em cada terço.

8. Renomear.

- 8.1 Renomear variedade para tratamento.
- 8.2 Renomear os terços para versões abreviadas com 3 dígitos.
- 8.3 Passar todas as variáveis para caixa alta.
- 8.4 Abreviar todas as variáveis para nomes com 3 dígitos.

9. Medidas descritivas gerais.

- 9.1 Total de ninfas no terço superior.
- 9.2 Total de ninfas em cada um dos terços.
- 9.3 Média e desvio-padrão de ninfas em cada terço.
- 9.4 Correlação do número de ninfas entre os terços (duas a duas).

10. Medidas descritivas por extrato.

- 10.1 Total de registros por variedade.
- 10.2 Total de registros por data.
- 10.3 Total de registros por variedade e data.
- 10.4 Total de ninfas no terço superior por data.
- 10.5 Total de ninfas nos 3 terços juntos por data.
- 10.6 Total de ninfas nos 3 terços juntos por variedade, ordene no final.
- 10.7 Total de ninfas nos 3 terços juntos por data e variedade.
Guardar em objeto para usar a seguir.
- 10.8 A variedade com mais ninfas em cada data.
- 10.9 A data com mais ninfas em cada variedade.