

# Apresentação de Resultados Experimentais para Processamento de Alto Desempenho em R

---

Vinícius Garcia Pinto, Lucas Leandro Nesi, Lucas Mello Schnorr

20 de abril de 2022



## Considerações Iniciais

---



**ERAD** | RS  
20  
22

# Quem somos nós

## Vinícius Garcia Pinto

Professor  
FURG

Orientador PPGComp  
vinicius.pinto@furg.br



## Lucas Leandro Nesi

Doutorando PPGC  
UFRGS

lnesi@inf.ufrgs.br



## Lucas Mello Schnorr

Professor  
UFRGS

Orientador PPGC  
schnorr@inf.ufrgs.br



# Preparando o ambiente para o minicurso

Acesse <https://exp-hpc.gitlab.io/erad-2022/>

## Computador de uso pessoal (caso não tenha o R e Rstudio instalados)

1. Obter e instalar o R e o Rstudio

```
1 sudo apt install r-base libclang-dev libxkbcommon-x11-0 libpq5
   libcurl4-openssl-dev libssl-dev
2 wget https://download1.rstudio.org/desktop/bionic/amd64/rstudio
   -2022.02.1-461-amd64.deb
3 sudo dpkg -i rstudio-2022.02.1-461-amd64.deb
```

SH

## PC do laboratório

1. abrir o Rstudio



# Preparando o ambiente para o minicurso

## Pacotes R (no Rstudio ou em um console R)

2. tentar executar os comandos abaixo

```
1 library("magrittr")
2 library("tidyr")
3 library("tibble")
4 library("readr")
```

R

```
5 library("dplyr")
6 library("ggplot2")
7 library("patchwork")
8 library("plotly")
```

R

3. em caso de falha, executar:

```
1 install.packages(
2   c("magrittr", "tidyr", "tibble", "readr", "dplyr", "ggplot2",
3     "patchwork", "plotly"))
```

R



## Dados para os exemplos

4. baixar os arquivos exemplo.csv e TOP500history.csv

```
wget https://exp-hpc.gitlab.io/erad-2022/exemplo.csv  
wget https://raw.githubusercontent.com/dlenski/top500/master/  
TOP500_history.csv
```

SH

ou

```
download.file("https://exp-hpc.gitlab.io/erad-2022/exemplo.csv")  
download.file("https://raw.githubusercontent.com/dlenski/top500/master  
/TOP500_history.csv", destfile = "TOP500_history.csv")
```

R

# Preparando o ambiente para o minicurso

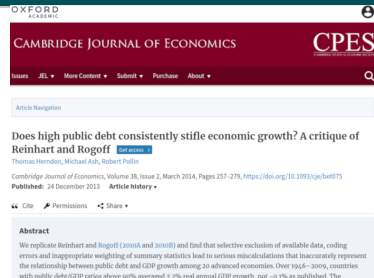
## Dados para os exemplos

### 5. leitura dos arquivos exemplo.csv e TOP500history.csv

```
read_csv("exemplo.csv",
         col_types = list(Maquina = col_character(),
                          A       = col_integer(),
                          B       = col_integer(),
                          Tempo   = col_double()),
         progress = FALSE) -> df_ex

library(lubridate)
read_csv("TOP500_history.csv", show_col_types = FALSE) %>%
  filter(!is.na(Region)) %>%
  mutate(Data = ymd(paste(Year, Month, Day))) %>%
  select(Data, Rank, RPeak, Region, Nmax) -> df.simple
```

- Processo metodológico para experimentos em PAD
  1. coleta dos dados
  2. análise dos resultados
- Reprodutibilidade da análise dos resultados é aspecto chave do processo científico
  - frequentemente subestimada
  - conduzida com ferramentas inapropriadas (pouca rastreabilidade)
  - diversos relatos de problemas, equívocos ou retratações
    - falhas metodológicas
    - falhas de manipulação e interpretação dos dados



OXFORD  
ACADEMIC

CAMBRIDGE JOURNAL OF ECONOMICS CPES

Issues JEL More Content Submit Purchase About

Article Navigation

Does high public debt consistently stifle economic growth? A critique of Reinhart and Rogoff [Full access](#)

Thomas Herndon, Michael Ash, Robert Pollin

Cambridge Journal of Economics, Volume 38, Issue 2, March 2014, Pages 257–279, <https://doi.org/10.1093/cje/bet075>

Published: 24 December 2013 [Article history](#)

Cite Permissions Share

**Abstract**

We replicate Reinhart and Rogoff (2010A and 2010B) and find that selective exclusion of available data, coding errors and inappropriate weighting of summary statistics lead to serious miscalculations that inaccurately represent the relationship between public debt and GDP growth among 20 advanced economies. Over 1946–2009, countries with public debt/GDP ratios above 90% averaged 3.2% real annual GDP growth, not –0.1% as published. The



naturemedicine

Explore content About the Journal Publish with us

nature > naturemedicine > news > article

Published: June 2010

**Data handling errors spur debate over clinical trial**

Stu Hutson

[Nature Medicine](#) 16, 618 (2010) | [Cite this article](#)

810 Accesses | 8 Citations | 83 Altmetric | [Metrics](#)

On 6 May, the US stock market experienced a peculiar 'minicrash' when what seems to be a mishandled trading order temporary sent stocks plummeting. The dramatic episode on Wall Street underscores how small errors can substantially upset data-heavy systems, and deciphering the error afterward can be a seemingly impossible task.



# Introdução

- Processo metodológico para experimentos em PAD
  1. coleta dos dados
  2. análise dos resultados
- Reprodutibilidade da análise dos resultados é aspecto chave do processo científico
  - frequentemente subestimada
  - conduzida com ferramentas inapropriadas (pouca rastreabilidade)
  - diversos relatos de problemas, equívocos ou retratações
    - falhas metodológicas
    - falhas de manipulação e interpretação dos dados





## Objetivos

- Apresentar uma abordagem baseada na linguagem R abrangendo desde o processamento dos dados brutos até a representação visual.
- Utilizar ferramentas modernas para permitir a documentação e a reprodutibilidade de todas as transformações e manipulações aplicadas aos dados

## Organização

### 1. Introdução à linguagem R

- comandos essenciais
- biblioteca base

### 3. Visualização

`ggplot2` `patchwork` `plotly`

### 2. Processamento de dados brutos

`readr` `tidyr` `magrittr`  
`dplyr` `tibble`

### 4. Prática

# Introdução à linguagem R

---



# A linguagem R

- Linguagem interpretada
- Multi-plataforma
- Código aberto (GPL v2)
- Foco em cálculos estatísticos, gráficos e análise de dados
- Extenso conjunto de pacotes
  - CRAN disponibiliza mais de 19000 pacotes (abril de 2022)
  - Várias maneiras de fazer a “mesma” coisa
- Extensa documentação
- Comunidade ampla e ativa



# Comandos básicos

comandos de atribuição <- e ->

aritmética básica -, +, \*, / e ^

operações relacionais <, >, ==, !=, >= e <=

comentários de linha #

```
1 x <- 100           # x recebe 100
2 100/3 + 2^2 -> y   # y recebe 37.33333...
3 z <- "escola regional de alto desempenho"
```

R



## construção function

- um nome
- argumentos (opcional)
  - *default values* também são possíveis
- retorno explícito com `return` (opcional)
  - na ausência de `return`, retorna o valor da última linha de código avaliada

```
aceleracao <- function(tseq, tpar){  
  return(tseq/tpar)  
}
```

R

```
raiz <- function(x, i = 2){  
  x^(1/i)  
}
```

R

**instalação de pacote(s)** `install.packages( nome(s) do(s) pacote(s) )`<sup>1</sup>  
**carregamento de um pacote** `library( nome do pacote )`  
**atualização dos pacotes instalados** `update.packages()`  
**remoção de pacotes** `remove.packages( nome(s) do(s) pacote(s) )`  
**documentação de pacote (ou função)** `?pacote (?funcao)`

```
install.packages("ggplot2")  
library(ggplot2)  
  
ggplot(mtcars, aes(x = mpg, y = cyl, color = gear)) +  
  geom_point()
```

R

---

<sup>1</sup>Por padrão, utiliza o CRAN (*Comprehensive R Archive Network* - <https://cran.r-project.org/>) que é o repositório oficial da linguagem R. Alternativamente, também pode ser usado para instalação a partir de arquivos locais.



## Vetores

- tipo mais simples de objeto R
- armazenam valores de um mesmo tipo básico (e.g., `logical`, `integer`, `numeric`, `complex`, `character` e `raw` [R C21])
- podem ser de tamanho 1
- indexados de 1 até N

## Matrizes

- vetores com mais de uma dimensão

## Lista

- similar a um vetor porém admite valores de diferentes tipos básicos



## Definição de vetores

```
d <- c(1, 5, 3) # d recebe 1 3 5
e <- 2:6        # e recebe 2 3 4 5 6
f <- seq(9, 5)  # f recebe 9 8 7 6 5
```

R

## Elementos nomeados

Listas e vetores podem ter seus valores internos nomeados (útil para indexação)

```
z <- c(prim = 1, seg = 5, terc = 3)
z["seg"] # acessa o elemento de nome 'seg'
z[c("prim", "terc")] # acessa os elementos 'prim' e 'terc'
```

R



## Data frames

- estruturas mais usadas para armazenamento de **dados experimentais**
  - casos (linhas)
  - variáveis (colunas)
- implementação
  - uma lista de vetores de mesmo tamanho
  - cada vetor desta lista possui um nome e representa uma variável
  - *Tibbles* são uma implementação moderna dos *Data frames*

	Maquina	A	B	Tempo
1	Mac1	0	0	20
2	Mac1	0	1	18
3	Mac1	1	0	16
4	Mac1	1	1	12
5	Mac2	0	0	25
6	Mac2	0	1	20
7	Mac2	1	0	25
8	Mac2	1	1	18

```
'data.frame': 8 obs. of 4 variables:  
 $ Maquina: chr "Mac1" "Mac1" "Mac1" "Mac1" ...  
 $ A : int 0 0 1 1 0 0 1 1  
 $ B : int 0 1 0 1 0 1 0 1  
 $ Tempo : num 20 18 16 12 25 20 25 18
```



- vetores podem ser operandos em expressões aritméticas → operação vetorial

```
a <- 1:5      # a recebe 1 2 3 4 5  
b <- a ^ 3    # b recebe 1 8 27 64 125  
c <- a + b    # c recebe 2 10 30 68 130
```

R

- atenção com vetores de tamanhos diferentes
  - resultado terá o tamanho do maior vetor
  - operandos menores são *reciclados*
  - warnings são emitidos apenas quando o tamanho do maior não é múltiplo do menor

$$a = [1 \ 2 \ 3 \ 4 \ 5]$$

$$b = a^3 [1 \ 8 \ 27 \ 64 \ 125]$$

$$c = a + b [2 \ 10 \ 30 \ 68 \ 130]$$



- muito útil para disponibilização do código da análise dos resultados e geração dos gráficos
  - facilita reexecuções
  - rastreamento integral → melhor reprodutibilidade
- exemplo: <https://exp-hpc.gitlab.io/erad-2022/companion.R>

```
#!/usr/bin/Rscript
args <- commandArgs(trailingOnly = TRUE)

print(paste("primeiro argumento:", args[1]))
print(paste("segundo argumento:", args[2]))
print(paste("terceiro argumento:", args[3]))
```

R

```
./meuscript.R arg1 arg2 arg3
```


SH

## Manipulação de resultados em texto puro

---




## Processo experimental



## Análise dos resultados

- resultados em formato texto (e.g., tempo, memória, energia, ...)
- pré-processamento, filtragem, transformação, interpretação e apresentação



- Resultados de experimentos de PAD usualmente são do tipo configuração vs métrica
  - exemplos de configurações: máquinas, rede, número de núcleos, versão sw
  - exemplos de métricas: tempo, memória, banda, energia
- *Data frame* (observações vs variáveis)
  - `read_csv` do pacote `readr` faz a leitura de dados “retangulares”

```
Maquina,A,B,Tempo
Mac1,0,0,20.0
Mac1,0,1,18.0
Mac1,1,0,16.0
Mac1,1,1,12.0
Mac2,0,0,25.0
Mac2,0,1,20.0
Mac2,1,0,25.0
Mac2,1,1,18.0
```

```
read_csv("exemplo.csv",
         col_types = list(Maquina = col_character(),
                          A       = col_integer(),
                          B       = col_integer(),
                          Tempo   = col_double()),
         progress = FALSE) -> df_ex
```





- operador `%>%` (*pipe*) do pacote `magrittr`
  - estilo convencional `fun(x, y)`
  - com encadeamento `x %>% fun(y)`
- melhora a legibilidade do código → as operações aparecem na ordem que acontecem de fato
- versão R 4.1.0 inclui um comando de *pipe* nativo `|>`



seleção de colunas comando select (pacote dplyr)

```
df_ex %>% select(Maquina, Tempo)
```

R

```
# A tibble: 8 × 2
  Maquina Tempo
  <chr>    <dbl>
1 Mac1      20
2 Mac1      18
3 Mac1      16
4 Mac1      12
5 Mac2      25
6 Mac2      20
7 Mac2      25
8 Mac2      18
```



ordenação das linhas comando `arrange` (pacote `dplyr`)

```
df_ex %>% arrange(A, B)
```

R

```
# A tibble: 8 × 4
  Maquina     A     B Tempo
  <chr>   <int> <int> <dbl>
1 Mac1         0     0    20
2 Mac2         0     0    25
3 Mac1         0     1    18
4 Mac2         0     1    20
5 Mac1         1     0    16
6 Mac2         1     0    25
7 Mac1         1     1    12
8 Mac2         1     1    18
```



**filtragem de linhas** comando `filter` (pacote `dplyr`)

```
df_ex %>% filter(Maquina %in% c("Mac1", "Mac2") & Tempo > 18)
```

R

```
# A tibble: 4 × 4
```

```
  Maquina      A      B Tempo
  <chr>    <int> <int> <dbl>
1 Mac1         0      0    20
2 Mac2         0      0    25
3 Mac2         0      1    20
4 Mac2         1      0    25
```



fatiamento por linhas comando `slice` (pacote `dplyr`)

```
df_ex %>% slice(2:4)
```

R

```
# A tibble: 3 × 4
  Maquina      A      B Tempo
  <chr>    <int> <int> <dbl>
1 Mac1         0      1    18
2 Mac1         1      0    16
3 Mac1         1      1    12
```



# Pivotagem

comando `pivot_longer` do pacote `tidyr` transforma para uma organização mais longa (**mais linhas**) enquanto `pivot_wider` para mais larga (**mais colunas**)

```
df_wid <- tibble(Nome = c("Alpha", "Beta"),  
                 Caso_A = c(1, 4),  
                 Caso_B = c(2, 5),  
                 Caso_C = c(3, 6))  
  
df_wid
```

R

```
# A tibble: 2 × 4  
  Nome    Caso_A Caso_B Caso_C  
  <chr>  <dbl> <dbl> <dbl>  
1 Alpha      1     2     3  
2 Beta      4     5     6
```



# Pivotagem

comando `pivot_longer` do pacote `tidyr` transforma para uma organização mais longa (**mais linhas**) enquanto `pivot_wider` para mais larga (**mais colunas**)

```
df_wid <- tibble(Nome = c("Alpha", "Beta"),
                 Caso_A = c(1, 4),
                 Caso_B = c(2, 5),
                 Caso_C = c(3, 6))

df_wid
```

R

```
# A tibble: 2 × 4
  Nome Caso_A Caso_B Caso_C
<chr> <dbl> <dbl> <dbl>
1 Alpha     1     2     3
2 Beta     4     5     6
```

```
pivot_longer(df_wid,
             c(Caso_A, Caso_B, Caso_C),
             names_to = "Variavel_1",
             values_to = "Valor") -> df_lon

df_lon
```

R

```
# A tibble: 6 × 3
  Nome Variavel_1 Valor
<chr> <chr> <dbl>
1 Alpha Caso_A     1
2 Alpha Caso_B     2
3 Alpha Caso_C     3
4 Beta  Caso_A     4
5 Beta  Caso_B     5
6 Beta  Caso_C     6
```

```
df_longer %>% pivot_wider(names_from = `Variavel_1`,  
                           values_from = Valor)
```

R

```
# A tibble: 2 × 4
```

	Nome	Caso_A	Caso_B	Caso_C
	<chr>	<dbl>	<dbl>	<dbl>
1	Alpha	1	2	3
2	Beta	4	5	6





criação de nova coluna comando `mutate` (pacote `dplyr`) utilizando outras colunas ou valores externos

```
df_ex %>% mutate(D = A + B)
```

R

```
# A tibble: 8 × 5
  Maquina     A     B Tempo     D
  <chr>   <int> <int> <dbl> <int>
1 Mac1         0     0    20     0
2 Mac1         0     1    18     1
3 Mac1         1     0    16     1
4 Mac1         1     1    12     2
5 Mac2         0     0    25     0
6 Mac2         0     1    20     1
7 Mac2         1     0    25     1
8 Mac2         1     1    18     2
```



**sumarizar uma coluna** comando `summarize` (pacote `dplyr`)

```
df_ex %>% summarize(media_t = mean(Tempo))
```

R

```
# A tibble: 1 × 1
  media_t
  <dbl>
1    19.2
```



# Combinando Tabelas

**combinação de conjuntos de dados distintos** comando `inner_join` (e outros comandos `*_join` providos pelo pacote `dplyr`)

```
# A tibble: 8 × 4
  Maquina     A     B Tempo
  <chr>   <int> <int> <dbl>
1 Mac1         0     0    20
2 Mac1         0     1    18
3 Mac1         1     0    16
4 Mac1         1     1    12
5 Mac2         0     0    25
6 Mac2         0     1    20
7 Mac2         1     0    25
8 Mac2         1     1    18
```

```
# A tibble: 2 × 2
  Nome  Cores
  <chr> <dbl>
1 Mac1    20
2 Mac2    24
```



# Combinando Tabelas

combinação de conjuntos de dados distintos comando `inner_join` (e outros comandos `*_join` providos pelo pacote `dplyr`)

```
# A tibble: 8 × 4
  Maquina     A     B Tempo
  <chr>   <int> <int> <dbl>
1 Mac1     0     0    20
2 Mac1     0     1    18
3 Mac1     1     0    16
4 Mac1     1     1    12
5 Mac2     0     0    25
6 Mac2     0     1    20
7 Mac2     1     0    25
8 Mac2     1     1    18
```

```
# A tibble: 2 × 2
  Nome     Cores
  <chr> <dbl>
1 Mac1    20
2 Mac2    24
```

```
inner_join(df_ex, maquinas,
           by = c("Maquina" = "Nome"))
```

R

```
# A tibble: 8 × 5
  Maquina     A     B Tempo Cores
  <chr>   <int> <int> <dbl> <dbl>
1 Mac1     0     0    20    20
2 Mac1     0     1    18    20
3 Mac1     1     0    16    20
4 Mac1     1     1    12    20
5 Mac2     0     0    25    24
6 Mac2     0     1    20    24
7 Mac2     1     0    25    24
8 Mac2     1     1    18    24
```



agrupamento de observações que compartilham uma mesma chave comando  
`group_by` (pacote `dplyr`)

```
df_ex %>% group_by(Maquina) %>% slice(1)
```

R

```
# A tibble: 2 × 4  
# Groups:   Maquina [2]  
  Maquina      A      B Tempo  
  <chr>    <int> <int> <dbl>  
1 Mac1         0      0    20  
2 Mac2         0      0    25
```



## Construção de gráficos

---



**ERAD** | RS  
20  
22

- O gráfico é descrito como uma combinação de dados, mapeamento e elementos geométricos

## Pacote ggplot2

```
ggplot(data = mtcars ,  
       mapping = aes(x = mpg, y = cyl, color = gear)) +  
  geom_point()
```

R



- O gráfico é descrito como uma combinação de dados, mapeamento e elementos geométricos

## Pacote ggplot2

```
ggplot(data = mtcars ,  
       mapping = aes(x = mpg, y = cyl, color = gear)) +  
  geom_point()
```

R

- construção incremental com uso do operador +

```
ggplot(data = mtcars ,  
       mapping = aes(x = mpg, y = cyl, color = gear)) +  
  geom_point() + geom_line() +  
  theme_light() + xlim(c(0, NA)) + ylim(c(0, NA))
```

R




# Gráficos Básicos

- comando `ggplot` do pacote `ggplot2`
  - conjunto de dados (e.g., *Data frame*)
  - estética básica com `aes()` (e.g., eixo x, eixo y, cores, formas, tamanho)
- comandos `geom_*` definem o estilo do gráfico
  - ex: `geom_point` para gráfico de pontos
  - cada estilo possui um conjunto de estéticas obrigatório

```
1 df.simple %>%  
2   filter(Rank == 1) %>%  
3   ggplot(aes(x = Data, y = RPeak)) +  
4   geom_line(alpha = 0.3) +  
5   geom_point() +  
6   theme_bw(base_size = 12)
```

R




- Como adicionar novas variáveis no gráfico?
  - Adição de elementos estéticos (aes) como cores, tamanhos e formas
  - Uso de **facetas**
- **Facetas** são úteis para visualização de variáveis que representam categorias, isto é, variáveis discretas
  - dividem um gráfico em vários sub-gráficos similares menores
  - `facet_wrap` cria sub-gráficos por linhas (uma variável)
  - `facet_grid` cria sub-gráficos por linhas e colunas (duas variáveis)



# Comparações com Facetas


```
1 df.simple %>%  
2   mutate(Year = year(Data)) %>%  
3   group_by(Year, Region) %>%  
4   summarize(Max.RPeak = max(RPeak)) %>%  
5   ggplot(aes(x = Year, y = Max.RPeak)) +  
6   geom_point()
```

R



```
1 df.simple %>%  
2   mutate(Year = year(Data)) %>%  
3   group_by(Year, Region) %>%  
4   summarize(Max.RPeak = max(RPeak)) %>%  
5   ggplot(aes(x = Year, y = Max.RPeak)) +  
6   geom_point() +  
7   facet_wrap(~Region)
```


R



# Comparações com Facetas

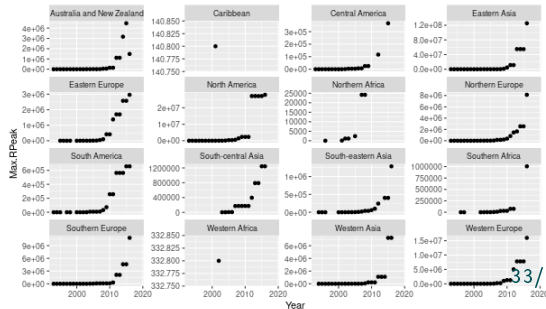
```
1 df.simple %>%  
2   mutate(Year = year(Data)) %>%  
3   group_by(Year, Region) %>%  
4   summarize(Max.RPeak = max(RPeak)) %>%  
5   ggplot(aes(x = Year, y = Max.RPeak)) +  
6   geom_point()
```

R



```
1 df.simple %>%  
2   mutate(Year = year(Data)) %>%  
3   group_by(Year, Region) %>%  
4   summarize(Max.RPeak = max(RPeak)) %>%  
5   ggplot(aes(x = Year, y = Max.RPeak)) +  
6   geom_point() +  
7   facet_wrap(~Region, scales = "free_y")
```

R



# Composição de Gráficos

- Por vezes, gostaríamos de combinar dois gráficos distintos em uma mesma figura
- Pacote `patchwork` permite compor gráficos criados com `ggplot`
  - operador `/` (empilhados)
  - operador `+` (lado a lado)
  - comando `wrap_plots`

```
1 df.simple %>%  
2   mutate(Year = year(Data)) %>%  
3   group_by(Year, Region) %>%  
4   summarize(Max.RPeak = max(RPeak)) %>%  
5   ggplot(aes(x = Year, y = Max.RPeak)) +  
6   geom_point() -> p1
```

R

```
1 p1 +  
2   facet_wrap(~Region,  
3             scales = "free_y") -> p2
```

R





# Composição de Gráficos

- Por vezes, gostaríamos de combinar dois gráficos distintos em uma mesma figura
- Pacote patchwork permite compor gráficos criados com ggplot
  - operador / (empilhados)
  - operador + (lado a lado)
  - comando wrap\_plots

```
1 df.simple %>%  
2   mutate(Year = year(Data)) %>%  
3   group_by(Year, Region) %>%  
4   summarize(Max.RPeak = max(RPeak)) %>%  
5   ggplot(aes(x = Year, y = Max.RPeak)) +  
6   geom_point() -> p1
```

```
1 p1 +  
2   facet_wrap(~Region,  
3             scales = "free_y") -> p2
```

p1 / p2



- Gráficos interativos permitem ir além da visão geral
  - navegar pelos valores
  - aproximar regiões do gráfico
  - desativar categorias
- Comando `ggplotly` do pacote `plotly` traduz um gráfico `ggplot2` para `plotly`

```
1 df.simple %>%  
2   filter(Rank == 1) %>%  
3   ggplot(aes(x = Data, y = RPeak)) +  
4     geom_point() -> p3  
5 ggplotly(p3)
```

A small grey square icon containing the letter 'R', representing the R programming language.

- Exemplos:

- <http://exp-hpc.gitlab.io/erad-2022/plotly-1.html>
- <http://exp-hpc.gitlab.io/erad-2022/plotly-2.html>



# Prática

---





# Exercício 1

Contabilize o número de sistemas de cada região em cada edição da lista do TOP500, ordenando a partir da lista mais recente.

```
# A tibble: 610 × 3
# Groups:   Data, Region [610]
  Data      Region      Total
  <date>   <chr>      <int>
1 2019-11-01 Australia and New Zealand    3
2 2019-11-01 Eastern Asia             263
3 2019-11-01 Eastern Europe         5
4 2019-11-01 North America          126
5 2019-11-01 Northern Europe           30
6 2019-11-01 South America          3
7 2019-11-01 South-central Asia        2
8 2019-11-01 South-eastern Asia        4
9 2019-11-01 Southern Europe          7
10 2019-11-01 Western Asia            5
# ... with 600 more rows
```



## Exercício 2

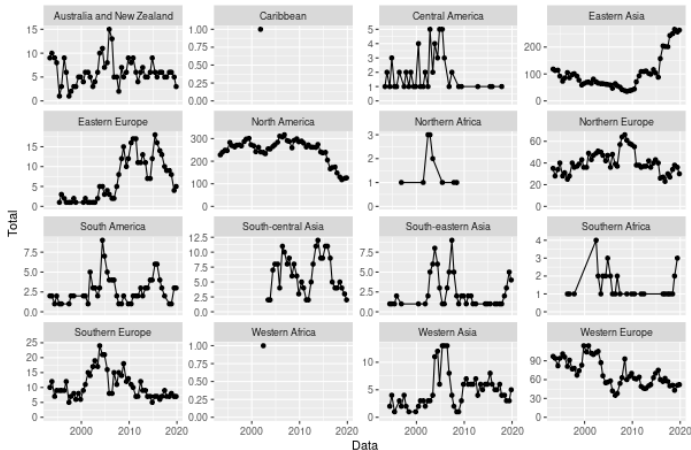
Contabilize em qual edição da lista cada uma das regiões teve sua maior representatividade, ordenando por ordem decrescente do total de sistemas.

```
# A tibble: 22 × 3
# Groups:   Region [16]
  Data      Region      Total
  <date>    <chr>      <int>
1 2006-11-01 North America    317
2 2018-11-01 Eastern Asia     266
3 1999-11-01 Western Europe   114
4 2000-11-01 Western Europe   114
5 2008-06-01 Northern Europe    66
6 2003-11-01 Southern Europe   24
7 2015-06-01 Eastern Europe    18
8 2005-11-01 Australia and New Zealand 15
9 2005-06-01 Western Asia     13
10 2005-11-01 Western Asia     13
# ... with 12 more rows
```



## Exercício 3

Faça um gráfico mostrando a quantidade de sistemas classificados ao longo do tempo com facetas por região do globo.



## Considerações Finais

---



**ERAD** | RS  
20  
22

- Abordagem em R para apresentação de resultados experimentais para PAD
  - Processamento dos dados brutos até a construção dos gráficos
  - Documentável e rastreável
- Assuntos correlatos em outras edições da ERAD
  - “Are you root? Experimentos Reprodutíveis em Espaço de Usuário” [DPNS21]
  - “Boas Práticas para Experimentos Computacionais de Alto Desempenho” [PNS20]
  - “Boas Práticas para Experimentos” [SP19]
- Entrem em contato para sugestões, colaborações, etc



Obrigado por participar e pela atenção!

Perguntas?

Contato

vinicius.pinto@furg.br

lucas.nesi@inf.ufrgs.br

schnorr@inf.ufrgs.br

Material do minicurso (slides, código, capítulo)

<https://exp-hpc.gitlab.io/erad-2022/>



ERAD

RS  
2022

40/43

## Referências

---



**ERAD** | RS  
20  
22

 Jessica Imlau Dagostini, Vinícius Garcia Pinto, Lucas Leandro Nesi, and Lucas Mello Schnorr.

**Are you root? Experimentos Reprodutíveis em Espaço de Usuário.**

In Andrea Charão and Matheus Serpa, editors, *Minicursos da XXI Escola Regional de Alto Desempenho da Região Sul*, chapter 3, pages 70–87. Sociedade Brasileira de Computação - SBC, Porto Alegre, 04 2021.




 Garrett Golemund.

***Hands-On Programming with R.***

O'Reilly Media, 1 edition, 2014.





-  Vinícius Garcia Pinto, Lucas Leandro Nesi, and Lucas Mello Schnorr.  
**Boas Práticas para Experimentos Computacionais de Alto Desempenho.**  
In André Rauber du Bois and Márcio Bastos Castro, editors, *Minicursos da XX Escola Regional de Alto Desempenho da Região Sul*, chapter 1, pages 1–19.  
Sociedade Brasileira de Computação - SBC, 04 2020.
-  R Core Team.  
***R Language Definition, 2021.***
-  Lucas Mello Schnorr and Vinícius Garcia Pinto.  
**Boas Práticas para Experimentos.**  
In *Anais da XIX Escola Regional de Alto Desempenho da Região Sul*, pages 45–64.  
Sociedade Brasileira de Computação - SBC, apr 2019.

-  Hadley Wickham and Garrett Golemund.  
***R for Data Science.***  
O'Reilly Media, 1 edition, 2017.

