Programación con R

Clase 2

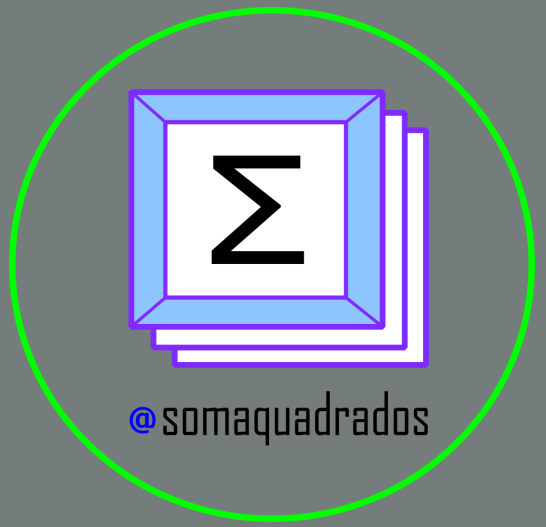

Marília Melo Favalesso

Archivos

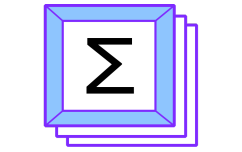

- `clase_2.R`
- `datos.csv`
- `datos.txt`
- `datos.xlsx`
- `tidy_ej.xlsx`

Contenido de hoy

- ¿Cómo armar mi tabla de datos?
- Tidyverse
- Importar datos a R
- Operador pipe (`%>%`)
- tidyr
- dplyr

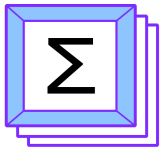

@somaquadrados

¿Cómo armar mi tabla de datos?

¿Cómo armar mi tabla de datos?

@somaquadrados

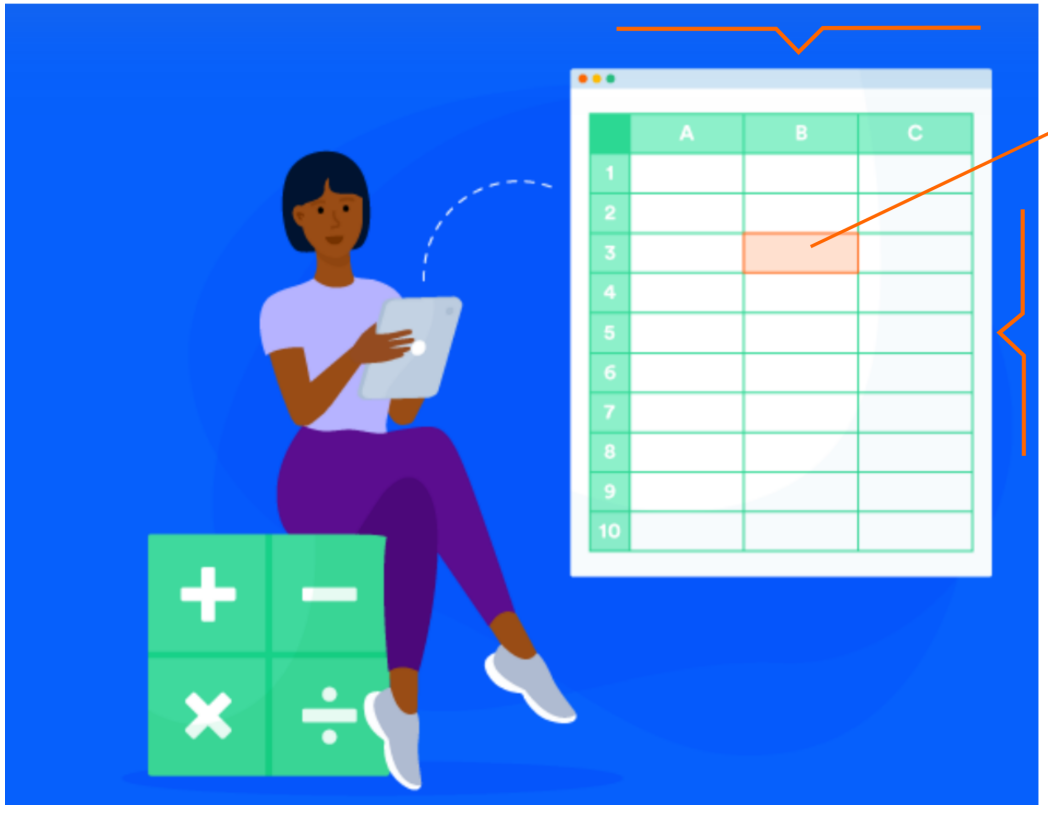

¿Cómo armar mi tabla de datos?

@somaquadrados

Variables en columnas

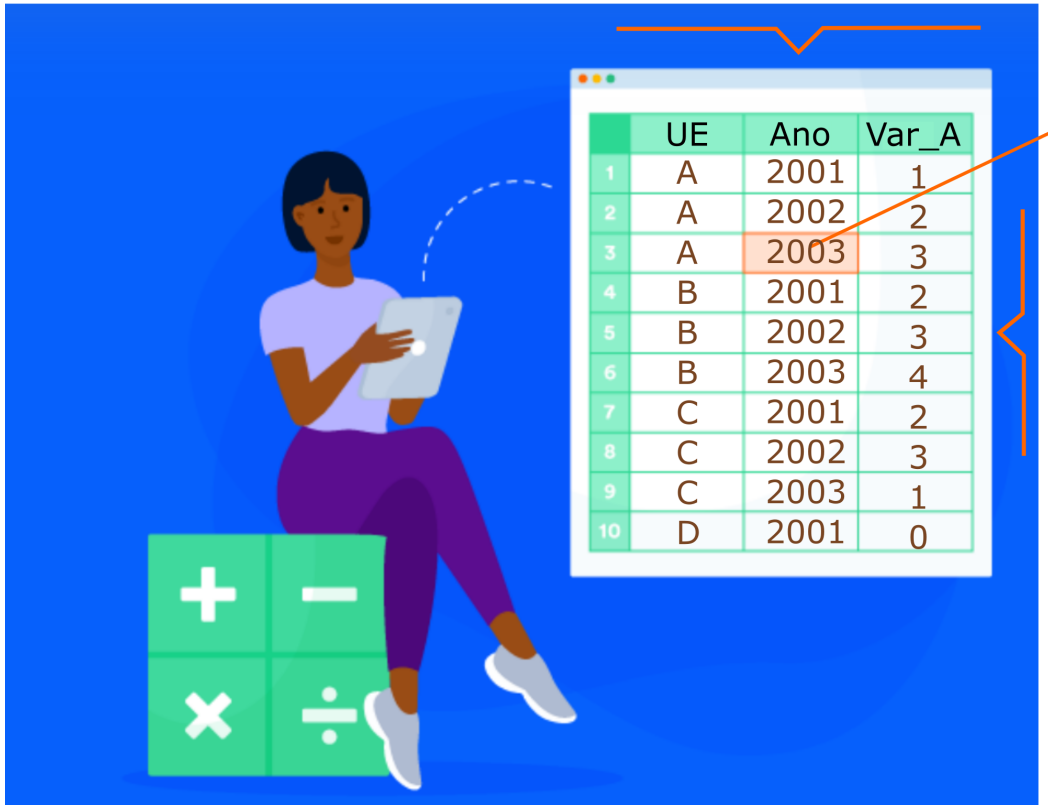

	UE	Ano	Var_A
1	A	2001	1
2	A	2002	2
3	A	2003	3
4	B	2001	2
5	B	2002	3
6	B	2003	4
7	C	2001	2
8	C	2002	3
9	C	2003	1
10	D	2001	0

¿Cómo armar mi tabla de datos?

Resumen

Características principales de un conjunto de datos ordenado:

- cada variable es una columna
- cada observación es una linea
- cada valor está en una celda diferente

¿Cómo armar mi tabla de datos?

@somaquadrados

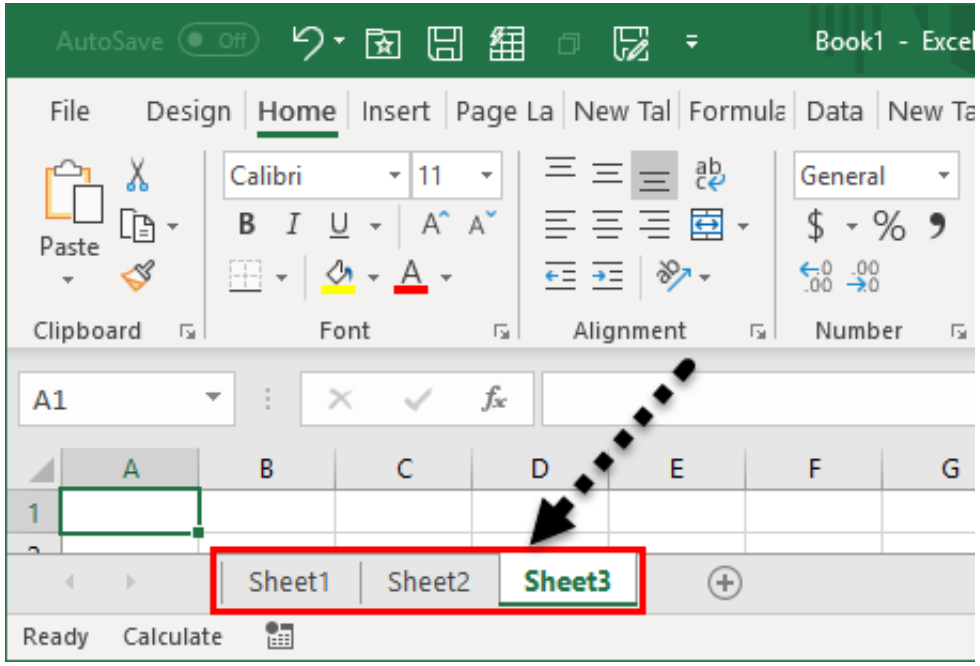

Descripción de datos:

- Utilice las hojas de datos de su editor (ex. excel) para almacenar información sobre su tabla.
- En la primera hoja (hoja 1) dejamos nuestra tabla y en las demás (normalmente la hoja 2, pero si es necesario usamos otras) incluimos información sobre nuestra tabla, como a qué se refieren los datos, descripción de cada variable, alguna observación importante y alguna fecha de edición de esta tabla.

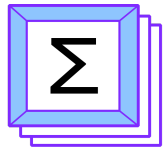

Tidyverse

https://www.tidyverse.org/

Tidyverse

@somaquadrados

> El tidyverse es una colección obstinada de R diseñados para la ciencia de datos. Todos los paquetes comparten una filosofía de diseño, una gramática y estructuras de datos subyacentes.

- Instale el tidyverse completo con:

```
install.packages("tidyverse")
```

Tidyverse


tidyverse


dplyr
ggplot2
readr
tidyr
forcats
tibble
purrr
stringr

Tidyverse

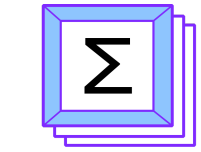

Tidyverse es una colección de R

- readr - importación de datos
- tibble - formato de `data.frame` mejorado
- tidyr, dplyr - manipulación de datos
- ggplot2 - visualizando de datos
- purrr - programación avanzada
- forcats - trabajando con factores
- stringr - trabajando con cadena de caracteres

Tidyverse

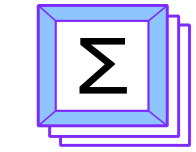

Tidyverse es una colección de R

- readr - importación de datos
- tibble - formato de `data.frame` mejorado
- tidyr, dplyr - manipulación de datos
- ggplot2 - visualizando de datos
- purrr - programación avanzada
- forcats - trabajando con factores
- stringr - trabajando con cadena de caracteres

Tidyverse

Flujo de trabajo en ciencia de datos, con Tidyverse

Tidyverse

@somaquadrados

El creador de **Tidyverse** es Hadley Wickham y hoy en día muchas personas han contribuido a su expansión.

http://hadley.nz/
@hadleywickham

Tidyverse

@somaquadrados

R for Data Science

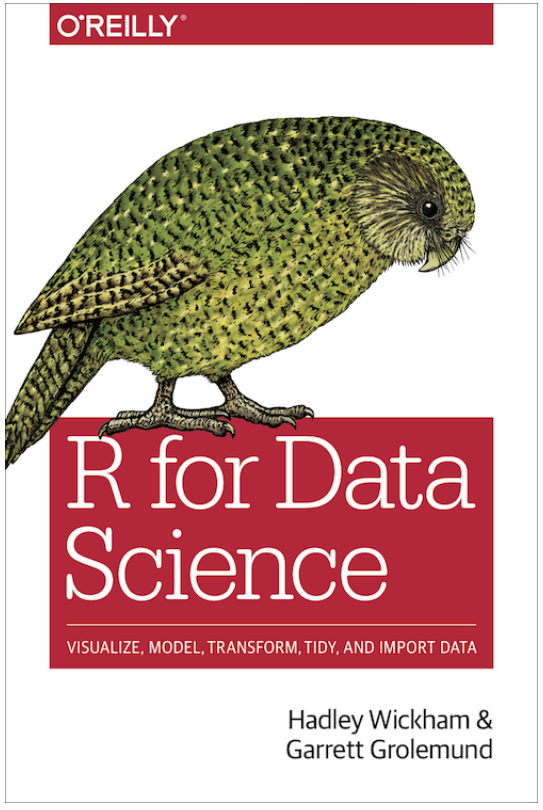

"This book will teach you how to do data science with **R**: You'll learn how to get your data into **R**, get it into the most useful structure, transform it, visualise it and model it. In this book, you will find a practicum of skills for data science. Just as a chemist learns how to clean test tubes and stock a lab, you'll learn how to clean data and draw plots—and many other things besides. (...)"

https://r4ds.had.co.nz/

Tidyverse

@somaquadrados

Instale y cargue el paquete **Tidyverse** en su computadora.

```
install.packages("tidyverse")
library(tidyverse)
```

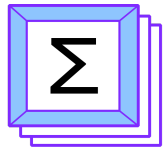

@somaquadrados

Importar datos a R

Importar datos a R

@somaquadrados

> Para su alivio, **no es necesario producir su tabla en R** (como lo hemos hecho hasta ahora). Es posible construir la tabla en Excel y luego importar los datos (de HD a nuestra memoria RAM).

> La función de importación dependerá del formato en el que se guardó nuestra tabla (.txt, .csv, .xls, .xlsx).

Importar datos a R

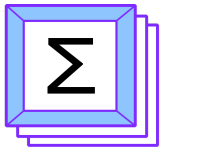

Working directory

- Recuerde que el directorio de trabajo es una 🗀 donde **R** lee y guarda archivos.
- Deberá decirle a R dónde están los archivos en los que va a trabajar.

```
# Aquí incluirá la dirección donde están sus archivos en su computadora.
setwd("C:/Users/mmfav/introduccionalR/clase_2/data")
```

- Deje todos los archivos guardados en esta misma carpeta, esto facilitará su trabajo.
- Tenga en cuenta que la dirección aquí se indica con barras invertidas (`/`), a diferencia de lo que usan algunos sistemas operativos (`\`). Por ejemplo:
  - : `C:\Users\mmfav\introduccionalR\clase_2\data`
  - : `C:/Users/mmfav/introduccionalR/clase_2/data`

Importar datos a R

@somaquadrados

El **tidyverse** `readr` se usa para importar archivos de texto, como *.txt* o *.csv* a **R**.

`reader` transforma archivos de texto en **tibbles**.

- `read_csv()`; `read_csv2`: para archivos separados por comas.
- `read_tsv()`: para archivos separados por tabulaciones.
- `read_delim()`: para archivos separados por un delimitador genérico. El argumento delim `=` indica qué carácter separa cada columna del archivo de texto.
- `read_table()`: para archivos de texto tabulares con columnas separadas por espacios.
- `read_fwf()`: para archivos compactos que deben tener el ancho de cada columna especificado.
- `read_log()`: para archivos de registro estándar.

Importar datos a R

@somaquadrados

El **tidyverse** `readr` se usa para importar archivos de texto, como *.txt* o *.csv* a **R**.

`reader` transforma archivos de texto en **tibbles**.

- `read_csv()`; `read_csv2`: para archivos separados por comas.
- `read_tsv()`: para archivos separados por tabulaciones.
- `read_delim()`: para archivos separados por un delimitador genérico. El argumento delim = indica qué carácter separa cada columna del archivo de texto.
- `read_table()`: para archivos de texto tabulares con columnas separadas por espacios.
- `read_fwf()`: para archivos compactos que deben tener el ancho de cada columna especificado.
- `read_log()`: para archivos de registro estándar.

Importar datos a R

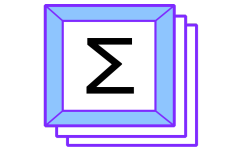

readr: `.csv`

- Como ejemplo, usaremos la base de datos que proporcionamos en el repositorio (datos.csv).
- La función para leer los datos es: `read_csv2(file = "archivo.csv")`.

```
datos_csv <- read_csv2(file = "datos.csv")
```

```
## i Using "','" as decimal and "'.'" as grouping mark. Use `read_delim()` for more control.

## Rows: 3 Columns: 5

## -- Column specification --------------------------------------------------------
## Delimiter: ";"
## chr (1): localidad
## dbl (4): ID, 2001, 2002, 2003

##
## i Use `spec()` to retrieve the full column specification for this data.
## i Specify the column types or set `show_col_types = FALSE` to quiet this message.
```

Importar datos a R

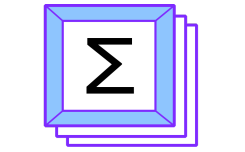

readr: `.csv`

- Como ejemplo, usaremos la base de datos que proporcionamos en el repositorio (datos.csv).
- La función para leer los datos es: `read_csv2(file = "archivo.csv")`.

```
datos_csv
```

```
## # A tibble: 3 x 5
##      ID localidad `2001` `2002` `2003`
##   <dbl> <chr>      <dbl>  <dbl>  <dbl>
## 1     1 Agricola      10     12     15
## 2     2 PNI           20     22     25
## 3     3 Urbano        15     12     10
```

Importar datos a R

readr: `.txt`

- Como ejemplo, usaremos la base de datos que proporcionamos en el repositorio (datos.txt).
- La función para leer los datos es: `read_delim(file = "archivo.txt", delim = "\t")`.

```
datos_txt <- read_delim(file = "datos.txt", delim = "\t")
```

```
## Rows: 6 Columns: 4

## -- Column specification --------------------------------------------------------
## Delimiter: "\t"
## chr (2): localidad, variable
## dbl (2): ID, value

##
## i Use `spec()` to retrieve the full column specification for this data.
## i Specify the column types or set `show_col_types = FALSE` to quiet this message.
```

Importar datos a R

@somaquadrados

readr: `.txt`

> "delim = " es un carácter único utilizado para separar campos dentro de un registro.

datos.txt - Bloco de Notas

Arquivo Editar Formatar Exibir Ajuda

ID	localidad	variable	value
1	Agricola	temperatura	25
1	Agricola	pluviosidad	10
2	PNI	pluviosidad	23
2	PNI	temperatura	22
3	Urbano	temperatura	30
3	Urbano	pluviosidad	30

*datos2.txt - Bloco de Notas

Arquivo Editar Formatar Exibir Ajuda

```
ID;localidad;variable;value
1;Agricola;temperatura;25
1;Agricola;pluviosidad;10
2;PNI;pluviosidad;23
2;PNI;temperatura;22
3;Urbano;temperatura;30
3;Urbano;pluviosidad;30
```

Importar datos a R

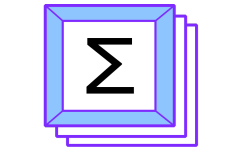

readr: `.txt`

- Como ejemplo, usaremos la base de datos que proporcionamos en el repositorio (datos.txt).
- La función para leer los datos es: `read_delim(file = "archivo.txt", delim = "\t")`.

```
datos_txt
```

```
## # A tibble: 6 x 4
##      ID localidad variable    value
##   <dbl> <chr>     <chr>       <dbl>
## 1     1 Agricola  temperatura    25
## 2     1 Agricola  pluviosidad    10
## 3     2 PNI       pluviosidad    23
## 4     2 PNI       temperatura    22
## 5     3 Urbano    temperatura    30
## 6     3 Urbano    pluviosidad    30
```

Importar datos a R

Exportar datos (`write_`)

- Para la mayoría de las funciones `read_`, existe una función `write_` correspondiente.
- Estas funciones sirven para guardar bases en un formato de archivo específico.
- Debe especificar el objeto a exportar y el nombre del archivo con la extensión.

```
# archivo .csv
write.csv2(x = objeto, path = "nombre_tabla.csv")

# como un .txt
write_delim(x = objeto, path = "nombre_tabla.txt", delim = "\t")
```

Importar datos a R

Exportar datos (`write_`)

- Para la mayoría de las funciones `read_`, existe una función `write_` correspondiente.
- Estas funciones sirven para guardar bases en un formato de archivo específico.
- Debe especificar el objeto a exportar y el nombre del archivo con la extensión.

```
# archivo .csv
write.csv2(x = datos_csv, path = "nombre_tabla.csv")

# como un .txt
write_delim(x = datos_txt, path = "nombre_tabla.txt", delim = "\t")
```

Importar datos a R

@somaquadrados

¿Qué pasa si mis datos se guardan como un archivo **excel**?

El `readxl` se usa para importar archivos de excel, como *.xslx* o *.xls* a **R**.

- Instalar:

```
install.packages("readxl")
```

- Cargar el paquete:

```
library(readxl)
```

- Para abrir nuestro archivo de repositorio (datos.xlsx): `read_xlsx("archivo.xlsx")`
- `readxl` transforma archivos de excel en **tibbles**.

- **¡¡No es parte del tidyverse !!**

Importar datos a R

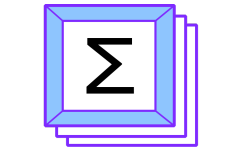

readxl: .xlsx

Ejemplo:

```
datos_xlsx <- read_xlsx("datos.xlsx")
```

Importar datos a R

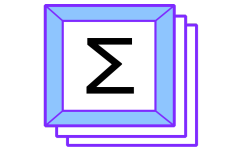

readxl: .xlsx

Ejemplo:

```
datos_xlsx
```

```
## # A tibble: 24 x 6
##       ID localidad                    ano zona     var_respuesta temperatura
##    <dbl> <chr>                      <dbl> <chr>            <dbl>       <dbl>
##  1     1 Puerto Iguazú - Misiones    2001 agrícola            NA        25
##  2     2 Puerto Liberdad - Misiones  2001 agrícola             2        26.7
##  3     3 San Pedro - Misiones        2001 agrícola             5        24.2
##  4     4 Tareiri - Misiones          2001 agrícola             4        26.2
##  5     5 Puerto Iguazú - Misiones    2005 agrícola             6        27
##  6     6 Puerto Liberdad - Misiones  2005 agrícola            NA        25.5
##  7     7 San Pedro - Misiones        2005 agrícola             7        26
##  8     8 Tareiri - Misiones          2005 agrícola             9        26.5
##  9     9 Puerto Iguazú - Misiones    2001 bosque              30        20
## 10    10 Puerto Liberdad - Misiones  2001 bosque              52        21
## # ... with 14 more rows
```

Importar datos a R

@somaquadrados

Un **tibble**, o `tbl_df`, es una reinvención moderna del `data.frame`, manteniendo el tiempo que ha demostrado ser efectivo y descartando lo que no lo es.

- Es un formato requerido para usar funciones **tidyverse**.
- Las variables pueden ser de tipo *numérico (int, dbl)*, *carácter (chr)*, *lógicas (lgl)* y *factor (fctr)*

- Convertir:

  > `data.frame` en `tibble`:

```
as_tibble(data)
```

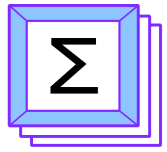

@somaquadrados

Operador pipe (%>%)

Operador pipe (%>%)

@somaquadrados

El 📦 `magrittr` ofrece un perador que hace que su código sea más legible: el pipe (`%>%`).

La idea del operador pipe (`%>%`) es bastante simple: use el valor resultante de la expresión de la izquierda como primer argumento de la función de la derecha.

Por ejemplo:

```
# suma el vector y luego obtén la √ (sqrt):
x <- 1:10
```

```
# Sin el pipe:
sqrt(sum(x))
```

```
## [1] 7.416198
```

```
# Con el pipe:
x %>% sum() %>% sqrt()
```

```
## [1] 7.416198
```

Operador pipe (%>%)

@somaquadrados

"Más intuitivo hacerlo un poco"

- **SIN** el pipe:

```
piensas(
  que(
    orden(
      la(
        en(
          codar()
          )
        )
      )
    )
  )
```

- **CON** el pipe:

```
codar() %>%
  en() %>%
  la() %>%
  orden() %>%
  que() %>%
  piensas()
```

!! El código no solo es más pequeño, es más intuitivo, la lectura se vuelve mucho más fácil **!!**

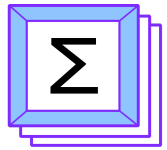

@somaquadrados

tidyr

tidyr

El objetivo del `tidyr` es ayudarte a crear datos ordenados.

Los datos ordenados son datos donde:

- Cada columna es variable.
- Cada fila es una observación.
- Cada celda es un valor único.

Tidyr data describe una forma estándar de almacenar datos que se utiliza siempre que sea posible en **tidyverse**.

Si se asegura de que sus datos estén ordenados, pasará menos tiempo luchando con las herramientas y más tiempo trabajando en su análisis.

---

tidyr

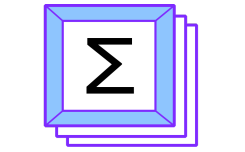

- Estas son sus principales funciones:
  - `separate()`: separar los caracteres en varias columnas
  - `unite()`: unir datos de varias columnas en una
  - `drop_na()`: eliminar líneas con NA
  - `replace_na()`: reemplazar valores NA
  - `pivot_wider()`: pasa valores de filas a columnas
  - `pivot_longer()`: pasa valores de columnas a filas

> Para ver todas las funciones del paquete, consulte la *cheatsheets*:
> https://github.com/rstudio/cheatsheets/blob/master/data-import.pdf

---

tidyr

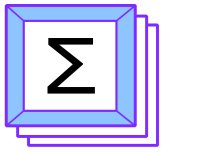

separate()

- Muchas veces, una sola variable de columna capturará múltiples variables, o incluso partes de una variable que simplemente no le importa.

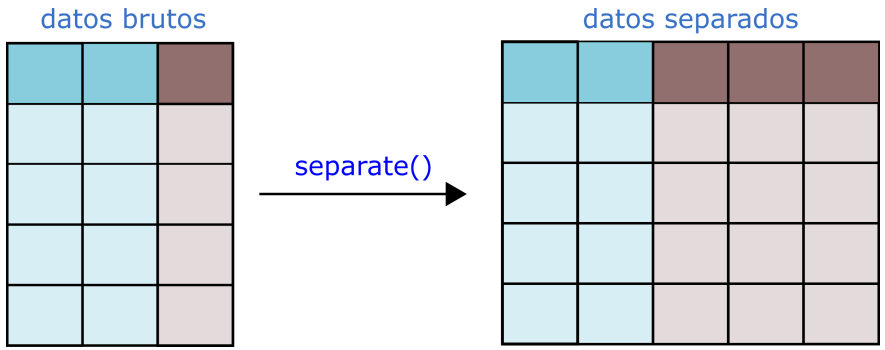

- La función `separate()` separa dos o más variables que están concatenadas en la misma columna.

- La sintaxis de la función es:

```
datos %>%
  separate(
    col = columna_vieja,
    into = c("nueva_columna_1", "nueva_columna_
    sep = c("_") # cómo se separan las variable
  )
```

tidyr

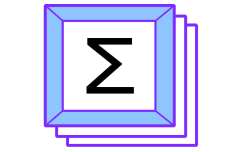

separate()

Por ejemplo, dividamos la columna "localidad" de la tabla "datos_xlsx" en "ciudad" y "provincia".

```
datos_xlsx %>%
  separate(
    col = localidad, # la columna vieja
    into = c("ciudad", "provincia"), # las nuevas columnas
    sep = c(" - ") # modo de separación
  )
```

Antes

ID	localidad	ano	zona	var_respuesta	temperatura
1	**Puerto Iguazú - Misiones**	2001	agrícola	NA	25.0

Despues

ID	ciudad	provincia	ano	zona	var_respuesta	tem
1	**Puerto Iguazú**	**Misiones**	2001	agrícola	NA	
2	**Puerto Liberdad**	**Misiones**	2001	agrícola	2	

tidyr

@somaquadrados

unite()

- La operación `unite()` es lo opuesto a `separate()`.

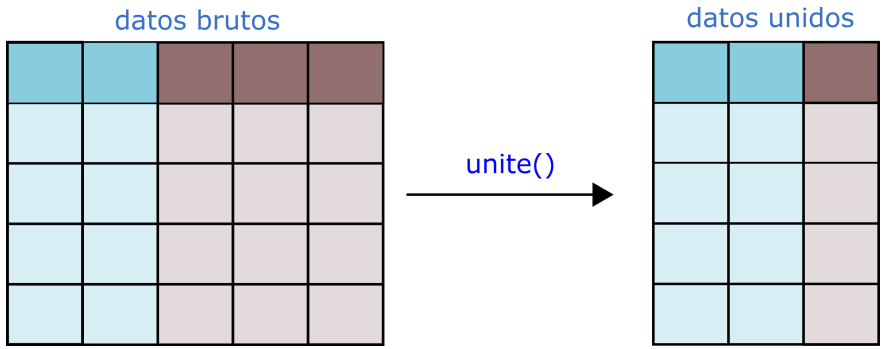

- La función `unite()` une dos variables que están en columnas diferentes.

- Toma dos columnas (variables) y las convierte en una. Se usa ampliamente para ensamblar informes finales o tablas para análisis visual.

- La sintaxis de la función es:

```
datos %>%
  unite(
    col = nueva_columna, columnas_para_juntar,
    sep = c("_") # cómo se separan las variable
  )
```

tidyr

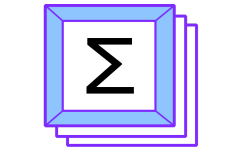

unite()

Por ejemplo, unamos las columnas "zona" y "año".

```
datos_xlsx %>%
  unite(
    col = "zona_ano", "zona", "ano",
    sep = "_"
  )
```

Antes

ID	localidad	ano	zona	var_respuesta	temperatura
1	Puerto Iguazú - Misiones	**2001**	**agrícola**	NA	25.0

Despues

ID	localidad	zona_ano	var_respuesta	temperatura
1	Puerto Iguazú - Misiones	**agrícola_2001**	NA	25.0
2	Puerto Liberdad - Misiones	**agrícola_2001**	2	26.7

tidyr

replace_na() y drop_na()

Cuando tenemos datos faltantes en nuestra tabla (NA), podemos reemplazar NA con nuevos valores con la función `replace_na()`,...

```
replace_na(
  list(columna_X = valor)
)
```

...o podemos eliminar las filas con valores faltantes con `drop_na()`.

```
drop_na(
  columna
)
```

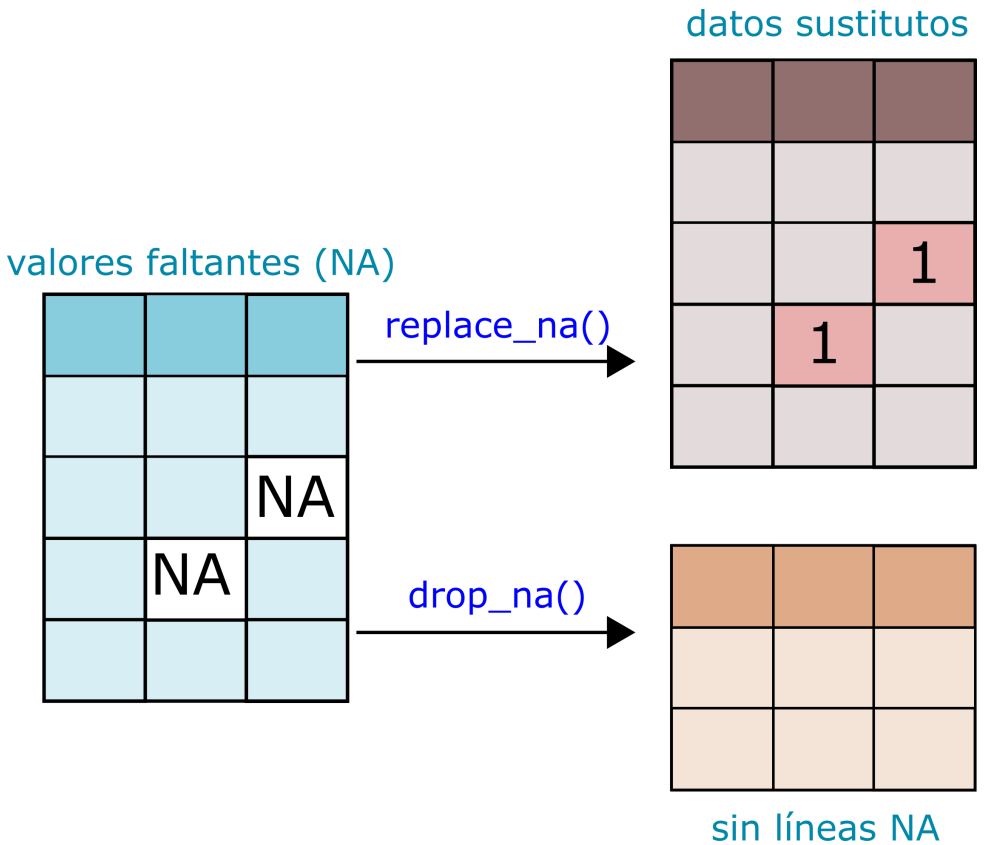

tidyr

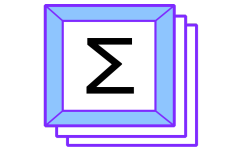

replace_na()

Por ejemplo, podemos reemplazar las filas con el valor faltante en la columna "var_respuesta" por cero (lineas 1, 6 y 20)...

```
datos_xlsx %>%
  replace_na(list(var_respuesta = 0))
```

Antes

ID	localidad	ano	zona	var_respuesta	temperatura
1	**Puerto Iguazú - Misiones**	**2001**	**agrícola**	**NA**	**25.0**
2	Puerto Liberdad - Misiones	2001	agrícola	2	26.7

Después

ID	localidad	ano	zona	var_respuesta	temperatura
1	**Puerto Iguazú - Misiones**	**2001**	**agrícola**	**0**	**25.0**
2	Puerto Liberdad - Misiones	2001	agrícola	2	26.7

tidyr

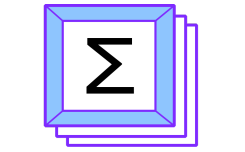

drop_na()

...o podemos eliminar las líneas que tiene valores NA.

```
datos_xlsx %>%
  drop_na(var_respuesta)
```

Antes

ID	localidad	ano	zona	var_respuesta	temperatura
1	Puerto Iguazú - Misiones	2001	agrícola	NA	25.0
2	Puerto Liberdad - Misiones	2001	agrícola	2	26.7
3	San Pedro	2001	agrícola	5	24.2

Después

ID	localidad	ano	zona	var_respuesta	temperatura
2	**Puerto Liberdad - Misiones**	**2001**	**agrícola**	**2**	**26.7**
3	San Pedro - Misiones	2001	agrícola	5	24.2

tidyr

@somaquadrados

pivot_longer()

- "Alarga" los datos, aumentando el número de filas y disminuyendo el número de columnas.

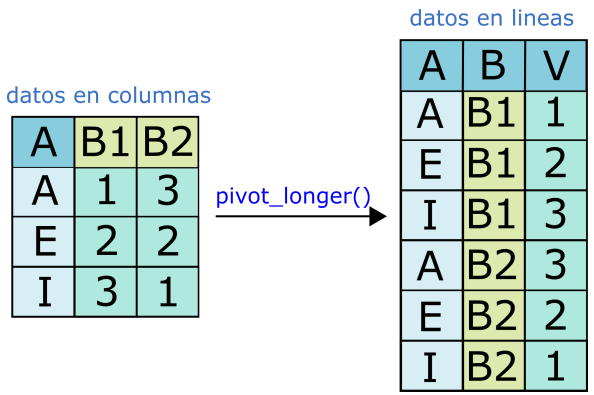


```
pivot_longer(
  cols = Columnas_para_pivotar,
  names_to = "nombre_nova_columna",
  values_to = "nombre_col_values"
  )
```

pivot_wider()

- Pasa los datos de columnas para filas, aumentando el número de columnas.

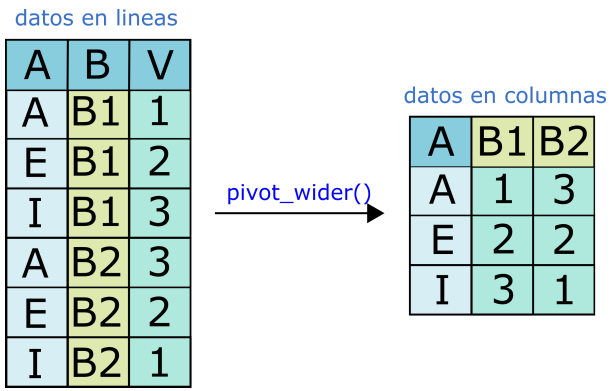


```
pivot_wider(
  names_from = columna_nombres,
  values_from = columna_valores
  )
```

tidyr

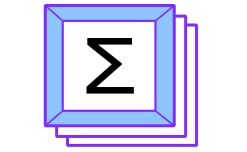

pivot_longer()

Por ejemplo, pasemos los años de la tabla "datos_csv" de las columnas a las filas. Los valores los almacenaremos en una columna llamada 'value'.

```
datos_csv
```

ID	localidad	2001	2002	2003
1	Agricola	10	12	15
2	PNI	20	22	25
3	Urbano	15	12	10

```
datos_csv %>%
  pivot_longer(
    cols = c('2001', '2002', '2003'),
    names_to = "año",
    values_to = "value"
  )
```

ID	localidad	año	value
1	Agricola	2001	10
1	Agricola	2002	12
1	Agricola	2003	15
2	PNI	2001	20
2	PNI	2002	22

tidyr

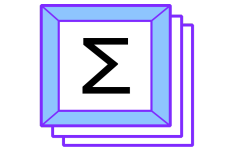

pivot_wider()

¿Qué pasa si quiero revertir la tabla a su formato original?

```
datos_csv2 %>%
  pivot_wider(
    names_from = año,
    values_from = value
  )
```

ID	localidad	2001	2002	2003
1	Agricola	10	12	15
2	PNI	20	22	25
3	Urbano	15	12	10

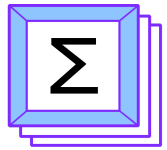

@somaquadrados

dplyr

dplyr

El `dplyr` es lo paquete más útil para realizar la transformación de datos, combinando simplicidad y eficiencia de una manera elegante.

- Los scripts **R** que hacen un uso inteligente de los verbos `dplyr` y las facilidades del operador `pipe` tienden a ser más legibles y organizados sin perder velocidad de ejecución.

- Las principales funciones de `dplyr` son:
  - `select()`: seleccionar columnas
  - `arrange()`: ordenar la base de datos
  - `filter()`: filtrar las lineas
  - `mutate()`: crear/modificar columnas
  - `group_by()`: agrupar la base de datos
  - `summarise()`: resume la base
  - `relocate()`: reordenar columnas
  - `left_join()`, `right_join()` y `full_join()`: juntar ≠ bases de datos.

dplyr

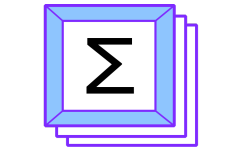

select()

- Usamos para seleccionar columnas.
- Los argumentos son los nombres de las columnas que desea seleccionar.

```
datos %>%
  select(nombre_col, nombre_col2)
```

- Para eliminar columnas de la base, agregue un "menos" (`-`) antes de la selección.

```
datos %>%
  select(-nombre_col, -nombre_col2)
```

- También disponemos de otras funciones auxiliares:
  - `starts_with()`: para columnas que comienzan con texto estándar
  - `ends_with()`: para columnas que terminan con texto estándar
  - `contiene()`: para columnas que contienen texto estándar

dplyr

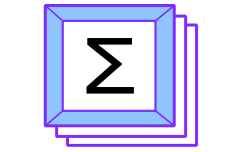

select()

Seleccionemos las columnas "localidad" y "año" de la tabla "datos_xlsx".

```
datos_xlsx %>%
  select(localidad, ano)
```

localidad	ano
Puerto Iguazú - Misiones	2001
Puerto Liberdad - Misiones	2001
San Pedro - Misiones	2001
Tareiri - Misiones	2001
Puerto Iguazú - Misiones	2005
Puerto Liberdad - Misiones	2005
San Pedro - Misiones	2005
Tareiri - Misiones	2005

dplyr

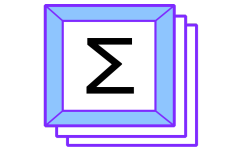

select()

Seleccione todos los datos excepto "ID" y "temperatura".

```
datos_xlsx %>%
  select(-ID, -temperatura)
```

localidad	ano	zona	var_respuesta
Puerto Iguazú - Misiones	2001	agrícola	NA
Puerto Liberdad - Misiones	2001	agrícola	2
San Pedro - Misiones	2001	agrícola	5
Tareiri - Misiones	2001	agrícola	4
Puerto Iguazú - Misiones	2005	agrícola	6
Puerto Liberdad - Misiones	2005	agrícola	NA
San Pedro - Misiones	2005	agrícola	7
Tareiri - Misiones	2005	agrícola	9

dplyr

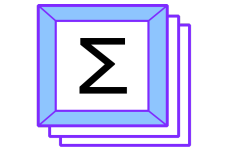

arrange()

- Para ordenar líneas.
- Los argumentos son las columnas por las que queremos ordenar las filas.

```
datos %>%
  arrange(columna_x)
```

- También podemos ordenar en orden descendente usando la función `desc()`

```
datos %>%
  arrange(desc(columna_x))
```

- ¡Y ordena más de una columna al mismo tiempo!

```
datos %>%
  arrange(columna_y, desc(columna_x))
```

dplyr

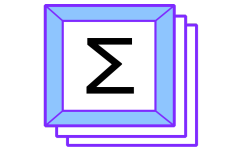

arrange()

- En el siguiente ejemplo, ordenamos las líneas base en orden ascendente de "response_var".

Antes

```
datos_xlsx %>%
  select(ano, var_respuesta)
```

ano	var_respuesta
2001	NA
2001	2
2001	5
2001	4
2005	6
2005	NA

Después

```
datos_xlsx %>%
  select(ano, var_respuesta) %>%
  arrange(ano, desc(var_respuesta))
```

ano	var_respuesta
2001	63
2001	52
2001	41
2001	30
2001	20
2001	16

dplyr

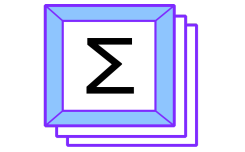

filter()

- Para filtrar valores de una columna base, usamos la función `filter()`.

```
datos %>%
  filter(columna < value)
```

- Por ejemplo, podemos seleccionar datos con una "var_respuesta" superior a 50.

```
datos_xlsx %>%
  filter(var_respuesta > 50)
```

ID	localidad	ano	zona	var_respuesta	temperatura
10	Puerto Liberdad - Misiones	2001	bosque	52	21
11	San Pedro - Misiones	2001	bosque	63	22
15	San Pedro - Misiones	2005	bosque	56	24
16	Tareiri - Misiones	2005	bosque	64	26

dplyr

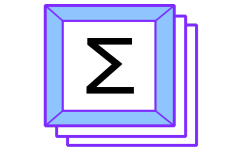

filter()

- También podemos usar el filtro con caracteres.

```
datos_xlsx %>%
  filter(zona %in% "urbano")
```

ID	localidad	ano	zona	var_respuesta	temperatura
17	Puerto Iguazú - Misiones	2001	urbano	20	28.0
18	Puerto Liberdad - Misiones	2001	urbano	14	29.4
19	San Pedro - Misiones	2001	urbano	16	32.4
20	Tareiri - Misiones	2001	urbano	NA	30.0
21	Puerto Iguazú - Misiones	2005	urbano	29	29.0
22	Puerto Liberdad - Misiones	2005	urbano	30	32.5
23	San Pedro - Misiones	2005	urbano	16	33.0
24	Tareiri - Misiones	2005	urbano	18	33.6

dplyr

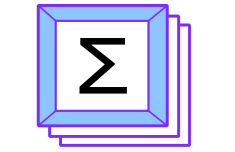

mutate()

- Para modificar una columna existente o crear una nueva.
- Aplicaremos una función.
- La regla es que el resultado de la operación devuelve un vector con una longitud igual al número de filas en la base.

```
datos_xlsx %>%
  mutate(columna = columna + función)
```

- También puede crear/modificar tantas columnas como desee dentro de la misma mutación.

```
datos_xlsx %>%
  mutate(columna = columna+función, nueva_columna = columna/valor)
```

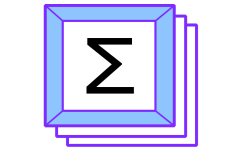

mutate()

- Por ejemplo, digamos que descubrió un error en su tabla. Agregaste uno individuo más en la columna "var_respuesta" y ahora necesitas quitar ese valor.

```
datos_xlsx %>%
  mutate(var_respuesta = var_respuesta - 1)
```

ID	localidad	ano	zona	var_respuesta	temperatura
1	Puerto Iguazú - Misiones	2001	agrícola	NA	25.0
2	Puerto Liberdad - Misiones	2001	agrícola	1	26.7
3	San Pedro - Misiones	2001	agrícola	4	24.2
4	Tareiri - Misiones	2001	agrícola	3	26.2
5	Puerto Iguazú - Misiones	2005	agrícola	5	27.0
6	Puerto Liberdad - Misiones	2005	agrícola	NA	25.5
7	San Pedro - Misiones	2005	agrícola	6	26.0

dplyr

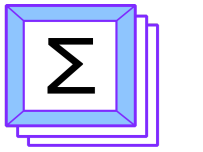

summarize()

- Es la técnica de resumir un conjunto de datos utilizando alguna métrica de interés.
- Media, mediana, varianza, frecuencia, proporción, por ejemplo, son tipos de resumen que aportan información diferente sobre una variable.

```
datos %>%
  summarize(función(columna))
```

- No vamos a explorar esta función aquí, ya que tendremos una clase solo sobre estadística descriptiva en **R**.

```
datos_xlsx %>%
  summarize(media = mean(temperatura), na.rm = TRUE)
```

```
## # A tibble: 1 x 2
##   media na.rm
##   <dbl> <lgl>
## 1  26.5 TRUE
```

dplyr

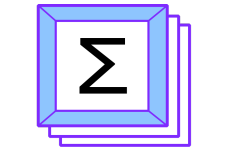

relocate()

- Para reubicar columnas.
- De forma predeterminada, coloca una o más columnas al comienzo de la base.

```
# Coloque las columnas 5 y 4 al principio de la tabla.
datos %>%
  relocate(columna5, columna4)
```

- Podemos usar los argumentos `.after =` y `.before =` para realizar cambios más complejos.

```
# Poner la columna 2 después de la columna 4
datos %>%
  relocate(columna2, .after = columna4)
```

```
# Poner la columna 2 antes de la columna 4
datos %>%
  relocate(columna2, .before = columna4)
```

dplyr

rename()

- Cambia los nombres de variables individuales (columnas) usando la sintaxis `nuevo_nombre = viejo_nombre`.

```
datos %>%
  rename(columna_x = columna.x)
```

- Por ejemplo, vamos cambiar el nombre de la columna "localidad" por "municipalidad".

Antes

```
datos_xlsx %>%
  names()
```

```
## [1] "ID"           "localidad"    "ano"
## [6] "temperatura"
```

Después

```
datos_xlsx %>%
  rename(municipalidad = localidad) %>%
  names()
```

```
 "zona"          "var_respuesta"
## [1] "ID"           "municipalidad" "ano"
## [6] "temperatura"
```

dplyr

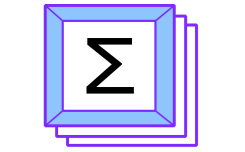

left_join(), right_join() y full_join()

- Lo usamos para unir dos tablas en una.

```
# Une la tabla 'datos' a la tabla 'datos2' por 'columna_x'

# Mantiene los elementos de la tabla 'datos' y excluye elementos adicionales de 'datos2'.
datos %>%
  left_join(datos2,
            by = "columna_x")

# Mantiene los elementos de la tabla 'datos2' y excluye elementos adicionales de 'datos'.
datos %>%
  right_join(datos2,
            by = "columna_x")

# Mantiene los valores de las dos tablas.
datos %>%
  full_join(datos2, by = "columna_x")
```

¡¡Fin de clase!!

@somaquadrados

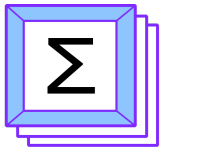

Soma dos quadrados

- Soma-Dos-Quadrados/introduccionalR
- /somaquadrados
- /somadosquadrados
- @somadosquadrados

Marília Melo Favalesso

- mariliabioufpr@gmail.com
- www.mmfava.com
- /mmfava