

Clase 1.3

Acomodo de datos

Marcos Rosetti y Luis Pacheco-Cobos
Estadística y Manejo de Datos con R (EMDR) — Virtual

Wrangling (arreo) de datos

Acomodo de datos



Acomodo de datos: **tidyr**



Acomodo de datos: **tidyverse**

- La filosofía de **tidyverse** es tener una forma estandarizada de acomodar los datos.
 - Cada *variable* es una **columna**.
 - Cada *observación* es una **fila**.
 - Tenemos *un solo un tipo* de información en **cada celda**.
 - Así la información resulta fácil de convertir y graficar.

Acomodo de datos: **tidy়**

- Formato largo/longitudinal vs ancho.

Formato "ancho"


name	gender	age	height	weight
Matt	M	20	180	80
Thomas	M	60	200	100
Cate	F	30	150	50

Formato "largo"

name	gender	feature	value
Matt	M	age	20
Matt	M	height	180
Matt	M	weight	80
Thomas	M	age	60
Thomas	M	height	200
Thomas	M	weight	100
Cate	F	age	30
Cate	F	height	150
Cate	F	weight	50

Acomodo de datos: **tidyverse**

- `gather()` sirve para pasar de formato **ancho** a formato **largo**.



Acomodo de datos: **tidyverse**

gather() colapsa múltiples columnas en dos columnas con:

1. una columna **key**, que contiene los nombres
2. una columna **value**, que contiene los valores

gather(casos, key, value, i:j)

data frame
a convertir

nombre de la
columna con
nombres

nombre de la
columna con
valores

índices o
nombres de
las columnas a
colapsar

Acomodo de datos: **tidy়r**

- Veamos unos datos: ¿qué problema tienen?

```
library(tidy়r)
```

```
table4b
```

```
## # A tibble: 3 × 3
##   country      `1999`    `2000`
## * <chr>        <int>     <int>
## 1 Afghanistan  19987071  20595360
## 2 Brazil       172006362  174504898
## 3 China        1272915272 1280428583
```

Acomodo de datos: **tidy**


- Los acomodamos o dejamos **tidy** (ordenados) con:

```
tidy.4b <- gather (table4b, key ="year", value="population", -country )  
tidy.4b
```

```
## # A tibble: 6 × 3  
##   country     year population  
##   <chr>       <chr>     <int>  
## 1 Afghanistan 1999     19987071  
## 2 Brazil      1999     172006362  
## 3 China       1999     1272915272  
## 4 Afghanistan 2000     20595360  
## 5 Brazil      2000     174504898  
## 6 China       2000     1280428583
```

Acomodo de datos: **tidy়**

- `spread()` sirve para pasar de formato largo a formato ancho.



Acomodo de datos: **tidyverse**

spread() expande dos columnas en múltiples columnas

1. una columna **key**, que contiene los nombres
2. una columna **value**, que contiene los valores

spread(casos, key, value)

data frame
a convertir

nombre de la
columna con
nombres

nombre de la
columna con
valores

Acomodo de datos: **tidy়**

- Veamos unos datos: ¿qué problema tienen?

```
head(table2)
```

```
## # A tibble: 6 × 4
##   country     year type      count
##   <chr>       <int> <chr>     <int>
## 1 Afghanistan 1999 cases      745
## 2 Afghanistan 1999 population 19987071
## 3 Afghanistan 2000 cases     2666
## 4 Afghanistan 2000 population 20595360
## 5 Brazil       1999 cases     37737
## 6 Brazil       1999 population 172006362
```

Acomodo de datos: **tidy**


- Los acomodamos o dejamos **tidy** (ordenados) con:

```
tidy.2 <- spread(table2, type, count)
tidy.2
```

```
## # A tibble: 6 × 4
##   country     year  cases population
##   <chr>       <int> <int>      <int>
## 1 Afghanistan 1999    745 19987071
## 2 Afghanistan 2000   2666 20595360
## 3 Brazil       1999  37737 172006362
## 4 Brazil       2000  80488 174504898
## 5 China        1999 212258 1272915272
## 6 China        2000 213766 1280428583
```


Acomodo de datos: **tidy়**

- Y de largo a ancho y viceversa.



Acomodo de datos: **tidyverse**

- `separate()` divide variables complejas en variables individuales.



Acomodo de datos: **tidyverse**

`separate(casos, col, into, sep)`

data frame
a unir

nombre de la
columna

vector con
los nombres
de las nuevas
columnas

caracter
que separa
los valores

Acomodo de datos: **tidy়**

- Veamos unos datos: ¿qué problema tienen?

```
head(table3)
```

```
## # A tibble: 6 × 3
##   country     year    rate
##   <chr>       <int> <chr>
## 1 Afghanistan 1999  745/19987071
## 2 Afghanistan 2000  2666/20595360
## 3 Brazil      1999  37737/172006362
## 4 Brazil      2000  80488/174504898
## 5 China       1999  212258/1272915272
## 6 China       2000  213766/1280428583
```

Acomodo de datos: **tidy**


- Los acomodamos o dejamos **tidy** (ordenados) con:

```
tidy.3 <- separate(table3, rate, c("cases", "population"), sep = "/")  
tidy.3
```

```
## # A tibble: 6 × 4  
##   country     year cases population  
##   <chr>       <int> <chr>    <chr>  
## 1 Afghanistan 1999  745  19987071  
## 2 Afghanistan 2000  2666 20595360  
## 3 Brazil      1999  37737 172006362  
## 4 Brazil      2000  80488 174504898  
## 5 China       1999  212258 1272915272  
## 6 China       2000  213766 1280428583
```

Acomodo de datos: **tidyverse**

- `unite()` une variables en una sola columna.



Acomodo de datos: **tidyverse**

`unite(casos, col, sep)`

data frame
a unir

nombre de la
columna a
separar

caracter
que separa
los valores

Acomodo de datos: **tidy়**

- Veamos unos datos: ¿qué problema tienen?

```
head(table5)
```

```
## # A tibble: 6 × 4
##   country    century year   rate
##   <chr>        <chr>  <chr> <chr>
## 1 Afghanistan 19     99    745/19987071
## 2 Afghanistan 20     00    2666/20595360
## 3 Brazil       19     99    37737/172006362
## 4 Brazil       20     00    80488/174504898
## 5 China        19     99    212258/1272915272
## 6 China        20     00    213766/1280428583
```

Acomodo de datos: **tidy**


- Los acomodamos o dejamos **tidy** (ordenados) con:

```
tidy.5 <- unite(table5, "year", 2:3, sep = "")  
tidy.5
```

```
## # A tibble: 6 × 3  
##   country     year    rate  
##   <chr>       <chr>   <chr>  
## 1 Afghanistan 1999 745/19987071  
## 2 Afghanistan 2000 2666/20595360  
## 3 Brazil      1999 37737/172006362  
## 4 Brazil      2000 80488/174504898  
## 5 China       1999 212258/1272915272  
## 6 China       2000 213766/1280428583
```

Acomodo de datos: **tidyverse**

- `extract()` divide una variable usando múltiples criterios y genera múltiples columnas.



Licencia CC BY



Estadística y Manejo de Datos con R (EMDR) por Marcos F. Rosetti S. y Luis Pacheco-Cobos se distribuye bajo una [Licencia Creative Commons Atribución 4.0 Internacional](#).