

# Rladies



## Resistencia Corrientes

Tutorial de dplyr

22 de Agosto de 2019



Realizado con Rmarkdown, xaringan y knitr



**Bienvenidas!!**



# ¿Qué vamos a ver hoy?

Funciones útiles

Funciones Principales + Tips

Split - Apply - Combine + Joins

# Nuestro material





<https://github.com/RLadiesResistenciaCorrientes/2019-dplyr-tips-tricks>

## Vignette de dplyr

<https://cran.r-project.org/web/packages/dplyr/vignettes/dplyr.html>

# Flujo de trabajo para Ciencia de Datos



data.frames




factors



strings






[\*] *Hands on programming with R* by Garret Golemund

# Dataset: gapminder




```
install.packages("gapminder")
install.packages("dplyr")
```


```
library(gapminder)
library(dplyr)
library(ggplot2)
ggplot2::ggplot(filter(gapminder, year
  scale_x_log10(labels = scales::dolla
  geom_point(aes(size = pop, fill = co
  scale_fill_brewer(palette = "Set2")
  scale_size_continuous(range = c(1, 2
  labs(title = "",
    subtitle = "Relación entre la e
    caption = "Fuente: Gapminder.org
    x = "PBI per capita ($)",
    y = "Edad (años)") +
  guides(size = FALSE) +
  theme(panel.grid.major.x = element_b
    legend.position = "right",
    legend.title = element_blank()
```



# gapminder en el tiempo



# El código



```
library(gganimate)
ggplot(gapminder, aes(gdpPercap, lifeExp, size = pop, colour = country)) +
  geom_point(alpha = 0.7) +
  scale_colour_manual(values = country_colors) +
  scale_size(range = c(2, 12)) +
  scale_x_log10() +
  facet_wrap(~continent) +
  theme(legend.position = 'none') +
  labs(title = 'Year: {frame_time}', x = 'GDP per capita', y = 'life expectancy')
transition_time(year)
```

# data.frame vs. tibble




- data.frame es una estructura nativas de rbase y está disponible sin necesidad de instalar ningún paquete adicional. Es una estructura tabular organizada en filas y columnas. Se puede acceder a las columnas mediante colnames() y los nombres de las filas, como rownames().
- tibble, sin embargo, es parte de tidyverse. También presenta una estructura tabular, en filas y columnas. Los tibbles eliminan los rownames por defecto, para tener mejor compatibilidad con bases de datos SQL.
- Ambas formas son intercambiables mediante los comandos

```
rbase::as.data.frame()  
tidyverse::as_tibble()
```

- Slicing

```
iris$Sepal.Length  
iris[["Sepal.Length"]]
```

```
iris %>% .$Sepal.Length  
iris %>% .[["Sepal.Length"]]
```



# Funciones Útiles

# Funciones Útiles



## Cargamos el paquete dplyr

```
library(dplyr)
library(gapminder)
```

## head()

```
head(gapminder)
```

```
## # A tibble: 6 x 6
##   country      continent  year  lifeExp      pop  gdpPercap
##   <fct>        <fct>    <int>  <dbl>    <int>    <dbl>
## 1 Afghanistan Asia      1952   28.8  8425333    779.
## 2 Afghanistan Asia      1957   30.3  9240934    821.
## 3 Afghanistan Asia      1962   32.0 10267083    853.
## 4 Afghanistan Asia      1967   34.0 11537966    836.
## 5 Afghanistan Asia      1972   36.1 13079460    740.
## 6 Afghanistan Asia      1977   38.4 14880372    786.
```

# Funciones Útiles



## tail()

```
tail(gapminder)
```

```
## # A tibble: 6 x 6
##   country continent  year lifeExp      pop gdpPercap
##   <fct>      <fct>    <int>  <dbl>    <int>    <dbl>
## 1 Zimbabwe Africa     1982   60.4  7636524   789.
## 2 Zimbabwe Africa     1987   62.4  9216418   706.
## 3 Zimbabwe Africa     1992   60.4 10704340   693.
## 4 Zimbabwe Africa     1997   46.8 11404948   792.
## 5 Zimbabwe Africa     2002   40.0 11926563   672.
## 6 Zimbabwe Africa     2007   43.5 12311143   470.
```

# Funciones Útiles



## glimpse()

```
glimpse(gapminder)
```

```
## Observations: 1,704
## Variables: 6
## $ country   <fct> Afghanistan, Afghanistan, Afghanistan, Afghanistan, ...
## $ continent <fct> Asia, Asia, Asia, Asia, Asia, Asia, Asia, Asia, Asia...
## $ year      <int> 1952, 1957, 1962, 1967, 1972, 1977, 1982, 1987, 1992...
## $ lifeExp   <dbl> 28.801, 30.332, 31.997, 34.020, 36.088, 38.438, 39.8...
## $ pop       <int> 8425333, 9240934, 10267083, 11537966, 13079460, 1488...
## $ gdpPercap <dbl> 779.4453, 820.8530, 853.1007, 836.1971, 739.9811, 78...
```

# Funciones Útiles



## slice()

```
dplyr::slice(gapminder, 5L)
```

```
## # A tibble: 1 x 6  
##   country      continent  year lifeExp      pop gdpPercap  
##   <fct>        <fct>    <int>  <dbl>    <int>    <dbl>  
## 1 Afghanistan Asia      1972   36.1 13079460    740.
```

# Funciones Útiles



## str()

```
str(gapminder)
```

```
## Classes 'tbl_df', 'tbl' and 'data.frame':   1704 obs. of  6 variables:
## $ country   : Factor w/ 142 levels "Afghanistan",...: 1 1 1 1 1 1 1 1 1 1 ...
## $ continent : Factor w/ 5 levels "Africa","Americas",...: 3 3 3 3 3 3 3 3 3 3 ...
## $ year      : int   1952 1957 1962 1967 1972 1977 1982 1987 1992 1997 ...
## $ lifeExp   : num   28.8 30.3 32 34 36.1 ...
## $ pop       : int  8425333 9240934 10267083 11537966 13079460 14880372 12881816 13867957
## $ gdpPercap: num   779 821 853 836 740 ...
```


# Funciones Útiles



## summary()

```
summary(gapminder)
```

```
##           country      continent      year      lifeExp
## Afghanistan: 12 Africa :624 Min. :1952 Min. :23.60
## Albania : 12 Americas:300 1st Qu.:1966 1st Qu.:48.20
## Algeria : 12 Asia :396 Median :1980 Median :60.71
## Angola : 12 Europe :360 Mean :1980 Mean :59.47
## Argentina : 12 Oceania : 24 3rd Qu.:1993 3rd Qu.:70.85
## Australia : 12 Max. :2007 Max. :82.60
## (Other) :1632
##           pop      gdpPercap
## Min. :6.001e+04 Min. : 241.2
## 1st Qu.:2.794e+06 1st Qu.: 1202.1
## Median :7.024e+06 Median : 3531.8
## Mean :2.960e+07 Mean : 7215.3
## 3rd Qu.:1.959e+07 3rd Qu.: 9325.5
## Max. :1.319e+09 Max. :113523.1
##
```



# Operador pipe

%>%

# Operador pipe %>%



- El operador pipe nos permite concatenar funciones y objetos en R, de forma que el código tenga un aspecto más ordenado, siguiendo la filosofía de tidyverse.


```
library(magrittr)
gapminder %>%
  filter(country=="Argentina")%>%
  select(gdpPercap, year) %>%
  head(2)
```

```
## # A tibble: 2 x 2
##   gdpPercap year
##   <dbl> <int>
## 1     5911.  1952
## 2     6857.  1957
```

- Sin operador pipe

```
head(select(filter(gapminder, country=="Argentina"), gdpPercap, year), 2)
```

```
## # A tibble: 2 x 2
##   gdpPercap year
##   <dbl> <int>
## 1     5911.  1952
## 2     6857.  1957
```



# Funciones principales de dplyr

`select()`: extraer columnas

`filter()`: extraer filas siguiendo una restricción lógica

`mutate()`: crea nuevas variables

`summarise()`: cambiar la unidad de análisis

`arrange()`: ordenar filas por variables

`group_by()`: agrupar según un determinado criterio



# Otras funcionalidades de dplyr

`dplyr_all`: aplica una operación a todas las variables

`dplyr_if`: aplica una operación a un set de columnas o filas que fueron seleccionadas según sus características

`dplyr_at`: aplica una operación a un set de columnas o filas basados en los nombres de las variables

# select()



- Podemos extraer columnas

```
gapminder %>%  
  select(country, lifeExp, gdpPercap)
```

```
## # A tibble: 1,704 x 3  
##   country      lifeExp gdpPercap  
##   <fct>        <dbl>    <dbl>  
## 1 Afghanistan  28.8      779.  
## 2 Afghanistan  30.3      821.  
## 3 Afghanistan  32.0      853.  
## 4 Afghanistan  34.0      836.  
## 5 Afghanistan  36.1      740.  
## 6 Afghanistan  38.4      786.  
## 7 Afghanistan  39.9      978.  
## 8 Afghanistan  40.8      852.  
## 9 Afghanistan  41.7      649.  
## 10 Afghanistan 41.8      635.  
## # ... with 1,694 more rows
```

[\*] Mas información en <https://dplyr.tidyverse.org/reference/select.html>

# Funciones útiles para combinar con `select()`



función	descripción
-	selecciona todas menos
:	selecciona un rango
<code>contains()</code>	selecciona variables cuyo nombre contiene...
<code>start_with()</code>	selecciona variables cuyo nombre empieza con ...
<code>ends_with()</code>	selecciona variables cuyo nombre empieza con...
<code>everything()</code>	selecciona todas las columnas
<code>matches()</code>	selecciona variables cuyo nombre coincide con...
<code>num_range()</code>	selecciona variables por posición

# Tip 1: si tenemos que seleccionar las mismas columnas varias veces



```
cols<-c("country", "lifeExp", "gdpPerCap")  
  
gapminder %>%  
  select(!cols)
```

```
## # A tibble: 1,704 x 3  
##   country      lifeExp gdpPerCap  
##   <fct>        <dbl>    <dbl>  
## 1 Afghanistan  28.8      779.  
## 2 Afghanistan  30.3      821.  
## 3 Afghanistan  32.0      853.  
## 4 Afghanistan  34.0      836.  
## 5 Afghanistan  36.1      740.  
## 6 Afghanistan  38.4      786.  
## 7 Afghanistan  39.9      978.  
## 8 Afghanistan  40.8      852.  
## 9 Afghanistan  41.7      649.  
## 10 Afghanistan 41.8      635.  
## # ... with 1,694 more rows
```

# Tip 2: seleccionar según una expresión regular (regex)



```
gapminder %>%  
  select(matches("gdp"))%>%  
  head
```

```
## # A tibble: 6 x 1  
##   gdpPercap  
##   <dbl>  
## 1     779.  
## 2     821.  
## 3     853.  
## 4     836.  
## 5     740.  
## 6     786.
```

# Tip 3: para reordenar columnas



```
gapminder %>%  
  select("lifeExp", "gdpPerCap", everything())%>%  
  head
```

```
## # A tibble: 6 x 6  
##   lifeExp gdpPerCap country      continent  year      pop  
##   <dbl>    <dbl> <fct>      <fct>      <int>    <int>  
## 1    28.8     779. Afghanistan Asia         1952  8425333  
## 2    30.3     821. Afghanistan Asia         1957  9240934  
## 3    32.0     853. Afghanistan Asia         1962 10267083  
## 4    34.0     836. Afghanistan Asia         1967 11537966  
## 5    36.1     740. Afghanistan Asia         1972 13079460  
## 6    38.4     786. Afghanistan Asia         1977 14880372
```

# select\_all()



- Permite seleccionar todas las columnas y aplicar una operación a todas las columnas

```
gapminder %>%  
  select_all(toupper) %>%  
  head
```

```
## # A tibble: 6 x 6  
##   COUNTRY      CONTINENT  YEAR LIFEEXP      POP GDPPERCAP  
##   <fct>        <fct>    <int> <dbl>    <int>    <dbl>  
## 1 Afghanistan Asia      1952  28.8  8425333  779.  
## 2 Afghanistan Asia      1957  30.3  9240934  821.  
## 3 Afghanistan Asia      1962  32.0 10267083  853.  
## 4 Afghanistan Asia      1967  34.0 11537966  836.  
## 5 Afghanistan Asia      1972  36.1 13079460  740.  
## 6 Afghanistan Asia      1977  38.4 14880372  786.
```

- Para deshacer el cambio anterior

```
gapminder %>%  
  select_all(tolower)
```

# Tip 4: renombrar las variables de una sola vez



```
iris %>%  
  head(1)
```

```
##   Sepal.Length Sepal.Width Petal.Length Petal.Width Species  
## 1           5.1           3.5           1.4           0.2  setosa
```

```
library(stringr)  
iris %>%  
  select_all(tolower) %>%  
  rename_all(~str_replace_all(., "\\.", "_")) %>%  
  head(2)
```

```
##   sepal_length sepal_width petal_length petal_width species  
## 1           5.1           3.5           1.4           0.2  setosa  
## 2           4.9           3.0           1.4           0.2  setosa
```

# filter()



- Realizamos el filtrado según un valor numérico de una variable. Para ello utilizamos los siguientes operadores: >, >=, <, =<, ==, !=

```
gapminder %>%  
  filter(lifeExp > 80) %>%  
  head(3)
```

```
## # A tibble: 3 x 6  
##   country    continent  year lifeExp      pop gdpPercap  
##   <fct>      <fct>      <int> <dbl>    <int>    <dbl>  
## 1 Australia Oceania     2002   80.4 19546792  30688.  
## 2 Australia Oceania     2007   81.2 20434176  34435.  
## 3 Canada    Americas    2007   80.7 33390141  36319.
```

[\*] Mas información en <https://dplyr.tidyverse.org/reference/filter.html>

# filter()



Podemos filtrar según múltiples condiciones:

- Se cumplen ambas condiciones

```
filter(condicion1, condicion2)
```

- Se cumple la condición 1 solamente

```
filter(condicion1, !condicion2)
```

- Se cumplen la condición 1 y/ o la condición 2

```
filter(condicion1 | condicion2)
```

- Se cumple una u otra condición, pero no ambas (disyunción exclusiva)

```
filter(xor(condicion1, condicion2))
```

# filter()



- Si queremos realizar un filtrado según un rango, lo hacemos de la siguiente manera

```
gapminder %>%  
  select (country, lifeExp, year) %>%  
  filter(lifeExp >= 60, lifeExp < 85) %>%  
  head
```

```
## # A tibble: 6 x 3  
##   country lifeExp year  
##   <fct>     <dbl> <int>  
## 1 Albania    64.8  1962  
## 2 Albania    66.2  1967  
## 3 Albania    67.7  1972  
## 4 Albania    68.9  1977  
## 5 Albania    70.4  1982  
## 6 Albania    72    1987
```

# Tip 5: usar `between()` para especificar rangos



- También podemos hacerlo combinando con `between()`:

```
gapminder %>%  
  select (country, lifeExp, year) %>%  
  filter(between(lifeExp, 60, 85)) %>%  
  head
```

```
## # A tibble: 6 x 3  
##   country lifeExp year  
##   <fct>     <dbl> <int>  
## 1 Albania    64.8  1962  
## 2 Albania    66.2  1967  
## 3 Albania    67.7  1972  
## 4 Albania    68.9  1977  
## 5 Albania    70.4  1982  
## 6 Albania    72    1987
```

# mutate()



- mutate() es una función que nos permite crear una nueva columna en un tibble, realizando una operación con otras ya existentes.

```
gapminder %>%  
  mutate(gdp = pop * gdpPercap) %>%  
  head
```

```
## # A tibble: 6 x 7  
##   country      continent  year lifeExp      pop gdpPercap      gdp  
##   <fct>        <fct>    <int> <dbl>    <int>    <dbl>    <dbl>  
## 1 Afghanistan Asia      1952  28.8  8425333  779.  6567086330.  
## 2 Afghanistan Asia      1957  30.3  9240934  821.  7585448670.  
## 3 Afghanistan Asia      1962  32.0 10267083  853.  8758855797.  
## 4 Afghanistan Asia      1967  34.0 11537966  836.  9648014150.  
## 5 Afghanistan Asia      1972  36.1 13079460  740.  9678553274.  
## 6 Afghanistan Asia      1977  38.4 14880372  786. 11697659231.
```

[\*] Más información en <https://dplyr.tidyverse.org/reference/mutate.html>

# Tip 6: Si queremos conservar sólo la nueva columna; usamos transmute()



```
gapminder %>%  
  transmute(gdp = pop * gdpPercap) %>%  
  head
```

```
## # A tibble: 6 x 1  
##           gdp  
##       <dbl>  
## 1  6567086330.  
## 2  7585448670.  
## 3  8758855797.  
## 4  9648014150.  
## 5  9678553274.  
## 6 11697659231.
```

# summarise()



```
gdp_bycontinents <- gapminder %>%  
  group_by(continent) %>%  
  summarize(mean_gdpPercap=mean(gdpPercap))  
gdp_bycontinents
```

```
## # A tibble: 5 x 2  
##   continent mean_gdpPercap  
##   <fct>         <dbl>  
## 1 Africa         2194.  
## 2 Americas       7136.  
## 3 Asia           7902.  
## 4 Europe        14469.  
## 5 Oceania       18622.
```

[\*] Más información en <https://dplyr.tidyverse.org/reference/summarise.html>

# Funciones útiles para combinar con summarise():



## rbase

funciones	descripción
min(), max()	valores mínimos y máximos
mean()	media
median()	mediana
sum()	suma de los valores
var(), sd()	varianza y desviación típica

## dplyr

dplyr	descripción
first()	primer valor de un vector
last()	último valor de un vector
n()	el numero de valores en un vector
n_distinct()	número de valores distintos en un vector
nth()	extraer el valor que ocupa la posición n en un vector

# summarise\_all()



- Requiere una función que se aplicará a todas las columnas

```
iris %>%  
  group_by(Species) %>%  
  summarise_all(mean)%>%  
  head
```

```
## # A tibble: 3 x 5  
##   Species    Sepal.Length Sepal.Width Petal.Length Petal.Width  
##   <fct>      <dbl>        <dbl>        <dbl>        <dbl>  
## 1 setosa      5.01          3.43          1.46          0.246  
## 2 versicolor 5.94          2.77          4.26          1.33  
## 3 virginica  6.59          2.97          5.55          2.03
```

# summarise\_at()



- Requiere dos argumentos, uno indicando las columnas que se tendrán en cuenta, y luego la operación con la que se resumirán los datos.

```
iris %>%  
  group_by(Species) %>%  
  summarise_at(vars(contains("Sepal")), mean)
```

```
## # A tibble: 3 x 3  
##   Species      Sepal.Length Sepal.Width  
##   <fct>         <dbl>         <dbl>  
## 1 setosa         5.01           3.43  
## 2 versicolor    5.94           2.77  
## 3 virginica     6.59           2.97
```

# summarise\_if():



- Requiere dos argumentos

```
gapminder %>%  
  group_by(continent) %>%  
  summarise_if(is.numeric, mean, na.rm=TRUE)
```

```
## # A tibble: 5 x 5  
##   continent  year lifeExp      pop gdpPercap  
##   <fct>      <dbl>  <dbl>    <dbl>    <dbl>  
## 1 Africa    1980.   48.9  9916003.   2194.  
## 2 Americas 1980.   64.7 24504795.   7136.  
## 3 Asia     1980.   60.1 77038722.   7902.  
## 4 Europe   1980.   71.9 17169765.  14469.  
## 5 Oceania  1980.   74.3  8874672.  18622.
```

# arrange()



- Podemos reordenar los datos según otro criterio, por ejemplo, en vez ordenar por países, reordenarlos según año.

```
gapminder %>%  
  arrange(year, country)
```

```
## # A tibble: 1,704 x 6  
##   country      continent  year  lifeExp      pop  gdpPercap  
##   <fct>        <fct>    <int>  <dbl>    <int>    <dbl>  
## 1 Afghanistan Asia      1952   28.8  8425333    779.  
## 2 Albania      Europe   1952   55.2  1282697   1601.  
## 3 Algeria      Africa   1952   43.1  9279525   2449.  
## 4 Angola       Africa   1952   30.0  4232095   3521.  
## 5 Argentina    Americas 1952   62.5  17876956  5911.  
## 6 Australia    Oceania  1952   69.1  8691212  10040.  
## 7 Austria      Europe   1952   66.8  6927772   6137.  
## 8 Bahrain      Asia     1952   50.9   120447   9867.  
## 9 Bangladesh  Asia     1952   37.5  46886859   684.  
## 10 Belgium     Europe   1952    68   8730405   8343.  
## # ... with 1,694 more rows
```

[\*] Más información en <https://dplyr.tidyverse.org/reference/arrange.html>

# arrange()



- Podemos reordenarlos de manera descendente

```
gapminder %>%  
  filter(year == 2007) %>%  
  arrange(desc(lifeExp))
```


```
## # A tibble: 142 x 6  
##   country      continent  year lifeExp      pop gdpPercap  
##   <fct>        <fct>    <int> <dbl>    <int> <dbl>  
## 1 Japan        Asia      2007  82.6 127467972 31656.  
## 2 Hong Kong, China Asia      2007  82.2  6980412 39725.  
## 3 Iceland      Europe    2007  81.8   301931 36181.  
## 4 Switzerland Europe    2007  81.7   7554661 37506.  
## 5 Australia    Oceania   2007  81.2  20434176 34435.  
## 6 Spain        Europe    2007  80.9  40448191 28821.  
## 7 Sweden       Europe    2007  80.9   9031088 33860.  
## 8 Israel       Asia      2007  80.7   6426679 25523.  
## 9 France       Europe    2007  80.7  61083916 30470.  
## 10 Canada      Americas  2007  80.7  33390141 36319.  
## # ... with 132 more rows
```

# Tip 7: Encontrar los top 5 valores más altos o más bajos



```
gapminder %>%  
  top_n(5, lifeExp) %>%  
  head
```

```
## # A tibble: 5 x 6  
##   country          continent  year lifeExp      pop gdpPercap  
##   <fct>            <fct>    <int>  <dbl>    <int>    <dbl>  
## 1 Hong Kong, China Asia      2007   82.2  6980412  39725.  
## 2 Iceland          Europe   2007   81.8   301931  36181.  
## 3 Japan            Asia     2002   82    127065841 28605.  
## 4 Japan            Asia     2007   82.6  127467972 31656.  
## 5 Switzerland     Europe   2007   81.7   7554661  37506.
```



# Split - Apply - Combine con dplyr

# Split - Apply - Combine con dplyr



- Definimos la función

```
fun <- function(slice, keys) {  
  broom::tidy(lm(Petal.Length ~ Sepal.Length, data = slice))  
}
```

- Aplicamos split - apply - combine

```
iris %>%  
  group_by(Species) %>%  
  group_modify(fun)
```

```
## # A tibble: 6 x 6  
## # Groups:   Species [3]  
##   Species    term      estimate std.error statistic  p.value  
##   <fct>     <chr>      <dbl>    <dbl>    <dbl>    <dbl>  
## 1 setosa    (Intercept) 0.803    0.344     2.34 2.38e- 2  
## 2 setosa    Sepal.Length 0.132    0.0685    1.92 6.07e- 2  
## 3 versicolor (Intercept) 0.185    0.514     0.360 7.20e- 1  
## 4 versicolor Sepal.Length 0.686    0.0863    7.95 2.59e-10  
## 5 virginica (Intercept) 0.610    0.417     1.46 1.50e- 1  
## 6 virginica Sepal.Length 0.750    0.0630   11.9 6.30e-16
```


# Tambien podemos hacerlo con una función anónima



- Una función anónima es una función que se define al momento que la estamos usando, y generalmente no tiene un nombre. En Python estas funciones se llaman funciones lambda.

```
iris %>%  
  group_by(Species) %>%  
  group_modify(~ broom::tidy(lm(Petal.Length ~ Sepal.Length, data = .x))  
)
```

```
## # A tibble: 6 x 6  
## # Groups:   Species [3]  
##   Species    term      estimate std.error statistic  p.value  
##   <fct>     <chr>      <dbl>    <dbl>    <dbl>    <dbl>  
## 1 setosa    (Intercept) 0.803    0.344     2.34 2.38e- 2  
## 2 setosa    Sepal.Length 0.132    0.0685    1.92 6.07e- 2  
## 3 versicolor (Intercept) 0.185    0.514     0.360 7.20e- 1  
## 4 versicolor Sepal.Length 0.686    0.0863    7.95 2.59e-10  
## 5 virginica (Intercept) 0.610    0.417     1.46 1.50e- 1  
## 6 virginica Sepal.Length 0.750    0.0630   11.9 6.30e-16
```



# Joins

# Joins



- Cuando trabajamos con más de un dataset y necesitamos crear una base de datos a partir de dos o más set de datos, necesitamos realizar una operación llamada **JOIN**
- Existen distintos tipos de **JOIN** según que dataset querramos generar, y, también de acuerdo a si se crean columnas nuevas (**mutating joins**) o solo filtramos filas (**filtering joins**)

## Mutating Joins



**left\_join()** retains all cases in **left** data set



**right\_join()** retains all cases in **right** data set



**full\_join()** retains all cases in **either** data set



**inner\_join()** retains all cases in **both** data set

[\*] Mas información en <https://dplyr.tidyverse.org/reference/join.html>

# Filtering Joins



`semi_join()` extracts cases that **have a match**



`anti_join()` extracts cases that **do not have a match**

```
dplyr::band_members
```

```
## # A tibble: 3 x 2
##   name band
##   <chr> <chr>
## 1 Mick  Stones
## 2 John  Beatles
## 3 Paul  Beatles
```

```
dplyr::band_instruments
```

```
## # A tibble: 3 x 2
##   name plays
##   <chr> <chr>
## 1 John  guitar
## 2 Paul  bass
## 3 Keith guitar
```

# Mutating Joins



## Left Join

```
band_members %>% left_join(band_instruments)
```

```
## # A tibble: 3 x 3
##   name band    plays
##   <chr> <chr>  <chr>
## 1 Mick  Stones <NA>
## 2 John  Beatles guitar
## 3 Paul  Beatles bass
```

## Right Join

```
band_members %>% right_join(band_instruments)
```

```
## # A tibble: 3 x 3
##   name band    plays
##   <chr> <chr>  <chr>
## 1 John  Beatles guitar
## 2 Paul  Beatles bass
## 3 Keith <NA>   guitar
```

# Full Join



```
band_members %>% full_join(band_instruments)
```

```
## # A tibble: 4 x 3
##   name band    plays
##   <chr> <chr>  <chr>
## 1 Mick  Stones <NA>
## 2 John  Beatles guitar
## 3 Paul  Beatles bass
## 4 Keith <NA>   guitar
```

# Inner Join

```
band_members %>% full_join(band_instruments)
```

```
## # A tibble: 4 x 3
##   name band    plays
##   <chr> <chr>  <chr>
## 1 Mick  Stones <NA>
## 2 John  Beatles guitar
## 3 Paul  Beatles bass
## 4 Keith <NA>   guitar
```

# Filtering Joins



## Semi Join


```
band_members %>% semi_join(band_instruments)
```

```
## # A tibble: 2 x 2
##   name band
##   <chr> <chr>
## 1 John  Beatles
## 2 Paul  Beatles
```

## Anti Join

```
band_members %>% anti_join(band_instruments)
```

```
## # A tibble: 1 x 2
##   name band
##   <chr> <chr>
## 1 Mick  Stones
```



¿Qué vemos?

Funciones básicas de dplyr

Trucos de dplyr

Split - Apply - Combine con dplyr


Joins


# Si tenemos dudas



Podemos consultar la documentación


```
?dplyr::select  
?dplyr::filter  
?dplyr::mutate  
?dplyr::arrange  
?dplyr::summarise  
?dplyr::group_by
```





Muchas Gracias!!

```
devtools::session_info()
```



```
## - Session info -----
## setting value
## version R version 3.6.1 (2019-07-05)
## os Windows 10 x64
## system x86_64, mingw32
## ui RTerm
## language (EN)
## collate Spanish_Argentina.1252
## ctype Spanish_Argentina.1252
## tz America/Buenos_Aires
## date 2019-08-22
##
## - Packages -----
## package * version date lib source
## assertthat 0.2.1 2019-03-21 [1] CRAN (R 3.6.1)
## backports 1.1.4 2019-04-10 [1] CRAN (R 3.6.0)
## broom 0.5.2 2019-04-07 [1] CRAN (R 3.6.1)
## callr 3.3.1 2019-07-18 [1] CRAN (R 3.6.1)
## cli 1.1.0 2019-03-19 [1] CRAN (R 3.6.1)
## colorspace 1.4-1 2019-03-18 [1] CRAN (R 3.6.1)
## crayon 1.3.4 2017-09-16 [1] CRAN (R 3.6.1)
## desc 1.2.0 2018-05-01 [1] CRAN (R 3.6.1)
## devtools 2.1.0 2019-07-06 [1] CRAN (R 3.6.1)
## digest 0.6.20 2019-07-04 [1] CRAN (R 3.6.1)
## dplyr * 0.8.3 2019-07-04 [1] CRAN (R 3.6.1)
## evaluate 0.14 2019-05-28 [1] CRAN (R 3.6.1)
## fansi 0.4.0 2018-10-05 [1] CRAN (R 3.6.1)
## farver 1.1.0 2018-11-20 [1] CRAN (R 3.6.1)
## fs 1.3.1 2019-05-06 [1] CRAN (R 3.6.1)
## gapminder * 0.3.0 2017-10-31 [1] CRAN (R 3.6.1)
## generics 0.0.2 2018-11-29 [1] CRAN (R 3.6.1)
## gganimate * 1.0.3 2019-04-02 [1] CRAN (R 3.6.1)
```

