data.table

por Mara Destéfanis

Uso y contribución del paquete data.table para análisis eficiente de BigData

Mara Destéfanis
maragdestefanis@gmail.com

Descargar las diapositivas desde: http://ml.nau.edu/latinr_spanish.pdf

Fundado por el programa NSF POSE, proyecto #2303612. diapositivas adaptadas de Toby Dylan Hocking, Arun Srinivasan, y datatable-viñeta de introducción - gracias!

¿Quien soy?

- Máster en Ciencia de Datos y Lic. Comunicación Social.
- Profesora en Colaboración con los Postgrado de Negocios de la Universidad de Belgrano Argentina y la Universidad Siglo XXI Argentina
- ¡Uso R desde el año 2021.
- Usuario de `data.table` desde 2023, contribuyo desde el año 2023.
- Consultora y Periodista Independiente.

Resumen de la presentación

1. ¿Qué es data.table?
2. ¿Porqué data.table es tan popular/poderoso? (eficiente)
3. Usando data.table para análisis eficiente de big data.
4. Contribuyendo a data.table

- Traducción de documentos de inglés a otro lenguaje, u$s500.
- Viajes de premios: u$s 2700 para hablar de data.table en conferencias.
- Participación en comunidad, problemas y solicitudes de extracción en GitHub.

1/4 ¿Qué es data.table?

data.frame en R

- Estructura de datos en columnas 2D
  - filas y columnas
  - subconjunto de filas `DF[DF$id != “a”, ]`
  - selección de columnas `DF[, “val”]`
  - subconjunto de filas & selección de columnas `DF[DF$id != “a”, “val”]`
- Por ahí va la cosa…

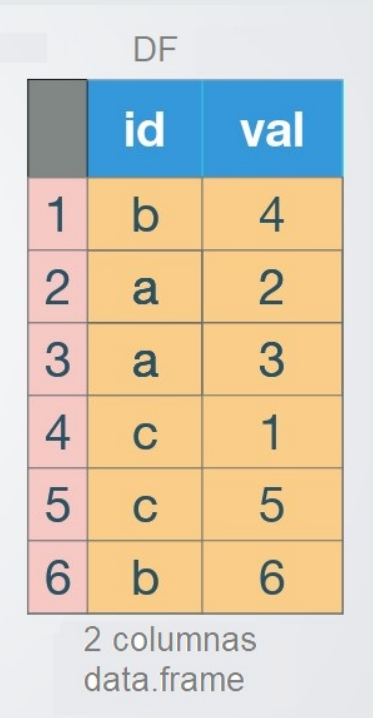

data.table

- Como data.frame, pero con más poder en la sintaxis de código R, y la implementación de código en C.
- Paquete R en CRAN desde 2006.
- Creado por Matt Dowle, co-autor Arun Srinivasan desde 2013, + 50 colaboradores.
- Hay 1463 paquetes en CRAN que requieren data.table (mas popular en porcentaje 0.05% de todos los paquetes de CRAN, rankea 11/19932 desde el 1 de octubre del 2023)

DF

	id	val
1	b	4
2	a	2
3	a	3
4	c	1
5	c	5
6	b	6

2 columnas
data.frame

data.table y tidyverse

- El paquete de tidyverse 1.0 se publicó en **CRAN** en el año 2016.
- Los paquetes de tidyverse tibble + readr + tidyr + dplyr ~= data.table
- tidyverse usa **DF |> … |>**, data.table uses **DT[…][…]**
- Tidyverse es verborrágico (tiene muchos códigos), data.table es conciso (pocos códigos) por ejemplo: tibble **|> filter(x==“a”) |> group_by(z) |> summarise(m=mean(y)) vs: DT[x==“a”, .(m=mean(y)), by=z]**

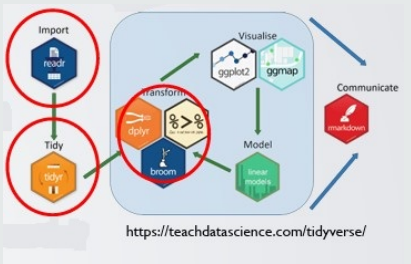

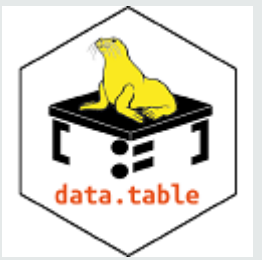

- Tidyverse tiene muchas dependencias, data.table no.(es fácil de instalar)
- Tidyverse con frecuencia presenta quiebres por cambios, data.table se asegura de tener compatibilidad (para los usuarios es fácil la **update** hacia nuevas versiones de data.table)

2/4 ¿Porqué data.table es tan popular/poderoso? (eficiente)

Porque Data table tiene dos clases de eficiencia

- Eficiencia en la **sintaxis de R** (permite reducir el tiempo de programación)
- Eficiencia en la **implementación de código C** (ya que reduce tiempo y memoria. Así un conjunto de datos puede analizarse con pocos recursos de cómputo)

Sintaxis de R con data table

- Piensa en términos básicos de unidades: filas, columnas, grupos.
- Matt habló en el 2014 a usuarios de R: https://youtu.be/qLrdYhizEMg?t=1m54s

Sintaxis del código R con data table

- Los datos también se estructuran en columnas.
  - 2D - `filas` y `columnas`
- `subset` de filas - DT[`id!="a"`,]
- `select` de columnas - DT[, `val`]
- `compute en` columnas - DT[, `mean(val)`]
- `subset` de filas & `select/ compute en` columnas - DT[`id!="a", mean(val)`]
- 3er dimensión virtual - `group by`

data.frame(DF) vs data.table(DT)

```
sum(DF[DF$code != “abd”, “valA”])
```

```
DT[code != “abd”, sum(valA)]
```

- Considera subconjuntos de filas con “abd” en columna de **code,** luego computa la suma de los valores en la columna **valA**.
- DF necesita que se repita, DT no lo requiere.
- `sum` puede ponerse en corchetes con DT rara vez en DF.

data.frame(DF) vs data.table(DT)

```
DF[DF$code == “abd”, “valA”] <- NA
```

```
DT[code == “abd”, valA := NA]
```

- Para los subconjuntos de filas con “abd” en columna `code`, setea los valores en la columna `vaIA` para valores perdidos/NA
- En DF necesitamos repetir, en DT no.
- DF usa asignación de flecha `\<-`, DT usa morsa `:=`

data.frame(DF) vs data.table(DT)

```
DF1 <- merge(DF1, DF2, all.x=TRUE)
DF1[, "valA"] <- ifelse(is.na(DF1$val),
                 DF1$valA, DF1$val)
DF1$val <- NULL
```

```
DT1[DT2, valA := val, on = .(id, code)]
```

- Summarize by group: considera el subgrupo de filas con "abd" en columna de code. Luego calcula la suma de los valores en las columnas`vaIA` y `vaIB`, para cada valor único de la columna de identificación.
- En DT todo está entre `corchetes DT []`, si usamos DF necesitamos usar otras funciones como por ejemplo: agregar **cbind**.

data.frame(DF) vs data.table(DT)

```
DF1 <- merge(DF1, DF2, all.x=TRUE)
DF1[, “valA”] <- ifelse(is.na(DF1$val),
                 DF1$valA, DF1$val)
DF1$val <- NULL
```

```
DT1[DT2, valA := val, on = .(id, code)]
```

- Modificar al unirse: cada fila de DT1 que coincida con una fila de DT2 en las columnas de identificación y code, setea valA en val.
- Fácil de hacer con DT, `:=` asignación y `on=` argumento.
- Con DF en base R es posible hacer pero difícil.

dos clases de eficiencia de data table

- Eficiencia en sintaxis de código R (permite disminuir el tiempo de programación)
- **Implementando código C es eficiente ya que disminuye el tiempo y la memoria (sobre todo cuando hay largos conjuntos de datos ya que permite analizarlos usando pocos recursos de cómputo)**

`data.table::fread` es extremadamente eficiente en lector de archivos CSV

Lee números reales de CSV, 100 x N

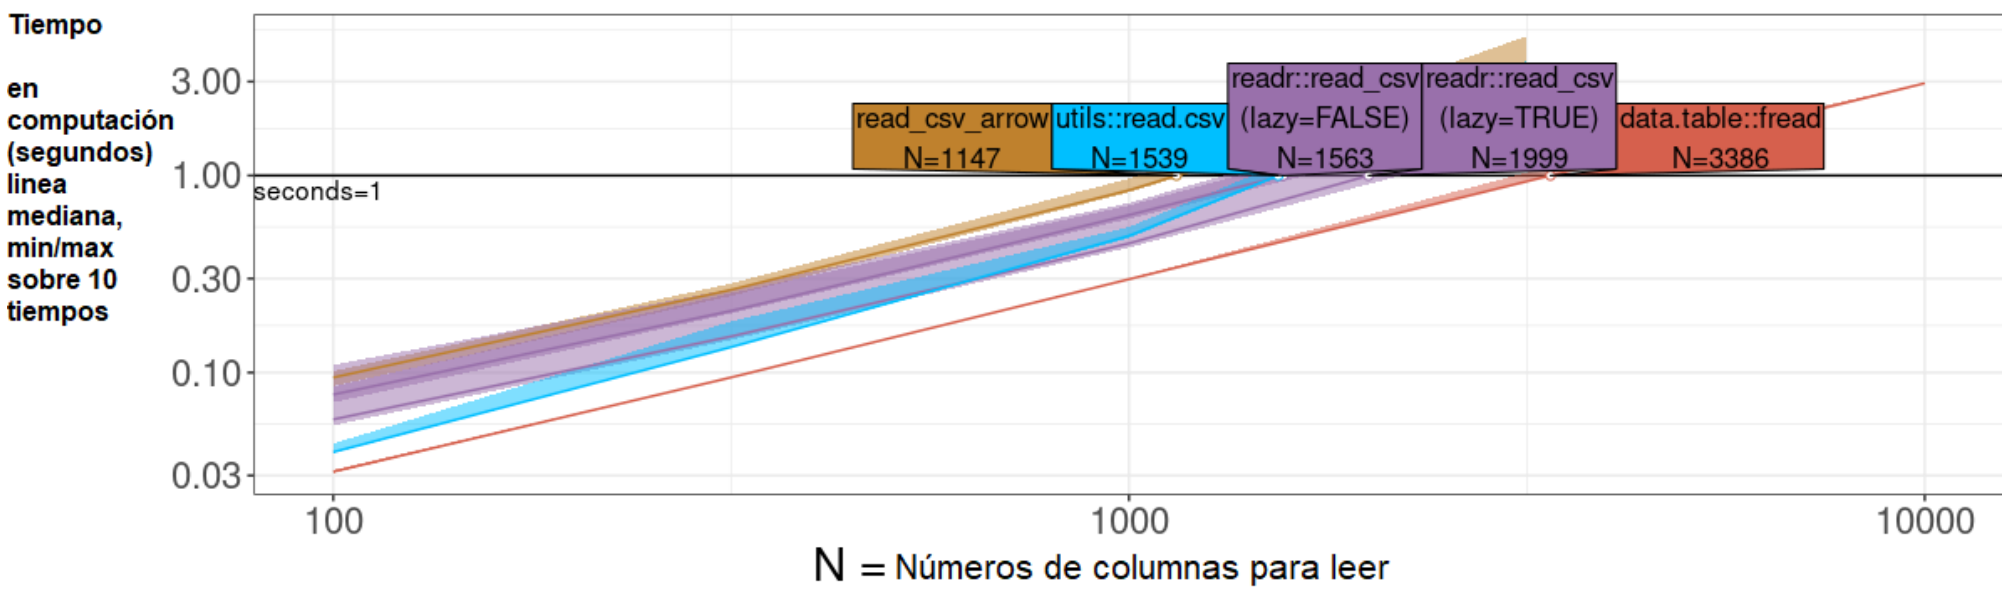

Fuente del código https://tdhock.github.io/blog/2023/dt-atime-figures/

data. table calcula resúmenes 100 veces más rápido que otros.

Promedio-mean-, desviación estándar -SD- sobre 10 números reales, *Ntimes*

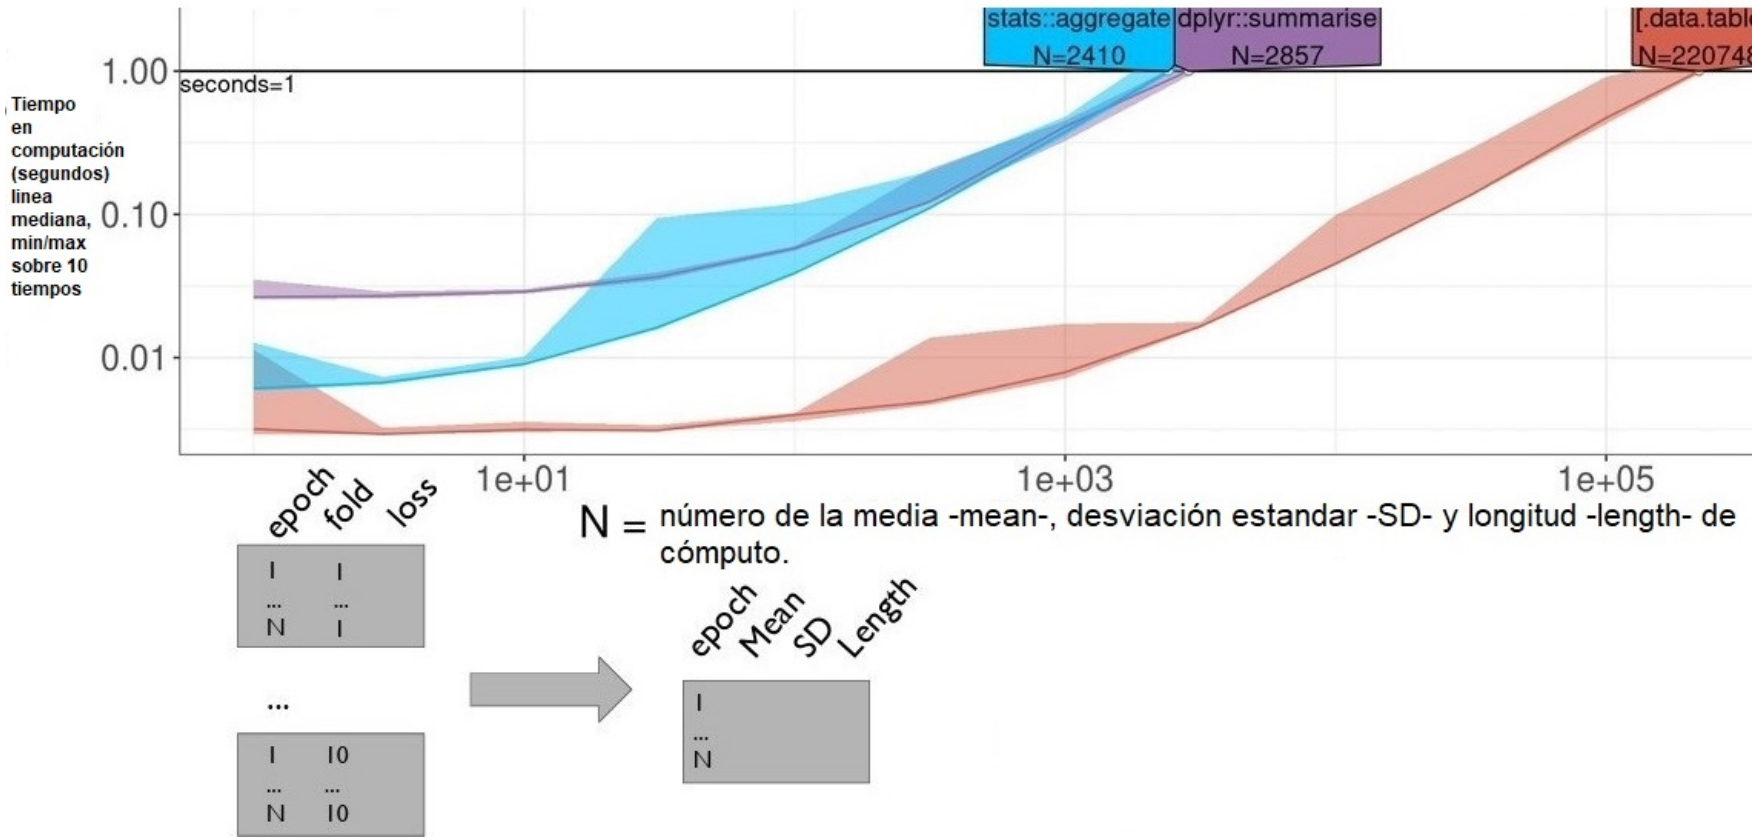

En Machine Learning, la validación cruzada k-fold estima la pérdida por hiperparámetros, como los nros. *epochs* de entrenamiento en una red neuronal. data.table puede computar eficientemente el promedio de pérdida sobre k=10, por cada N *epochs*

data.table::fwrite es extremadamente eficiente CSV file writer

Escribe números reales desde CSV, 100 x N

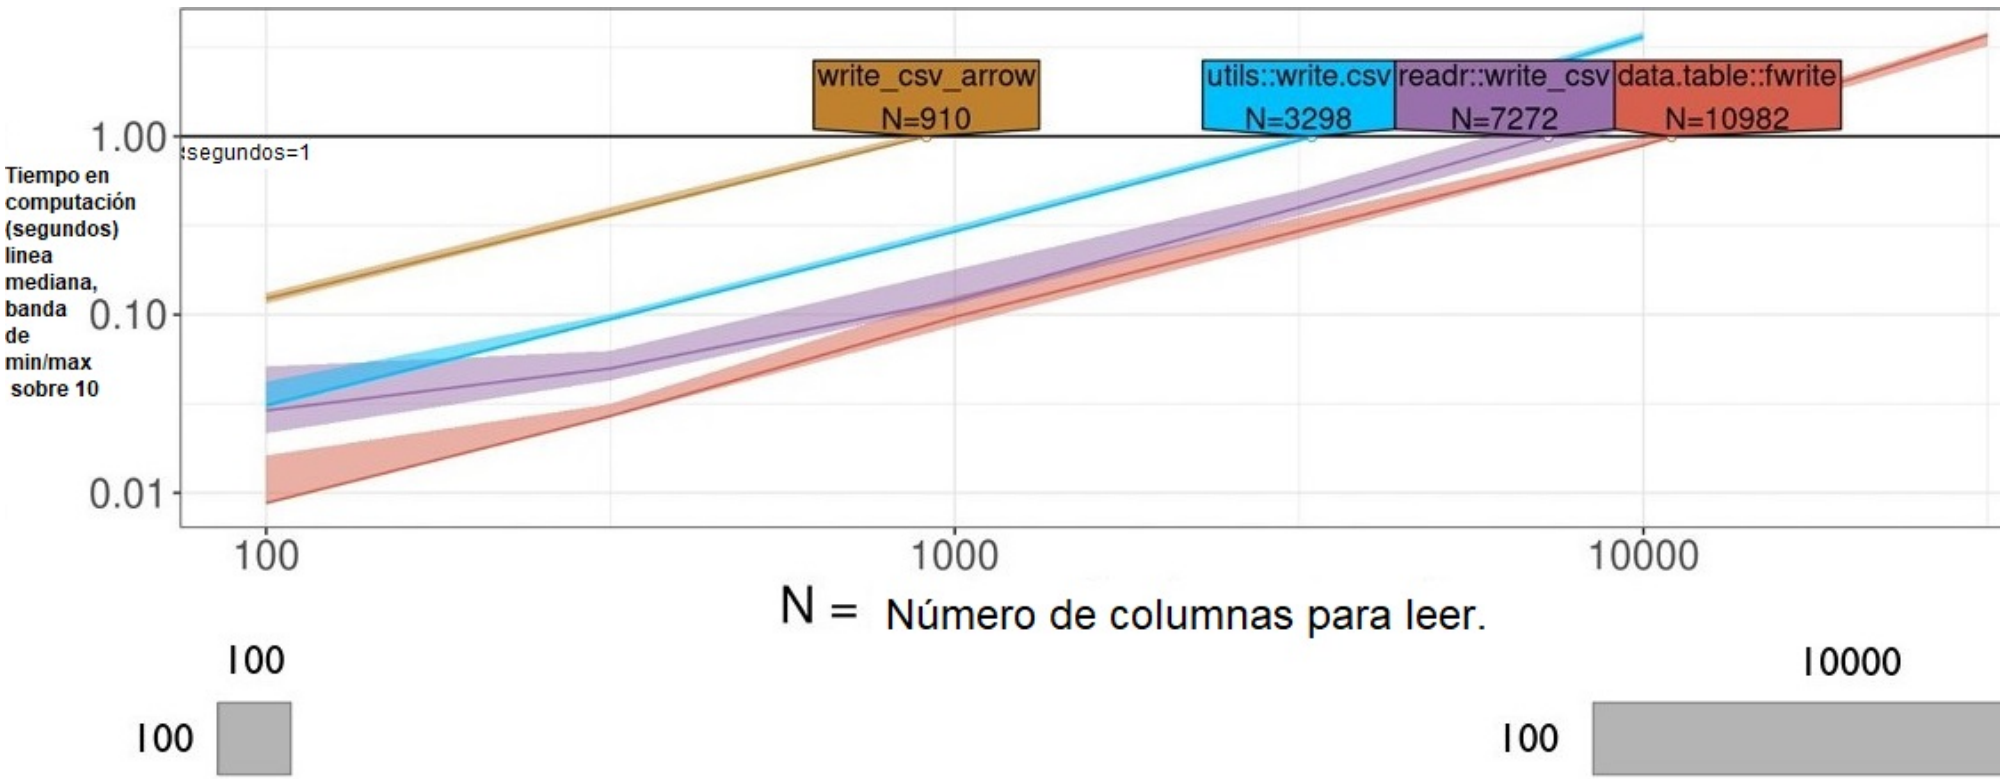

Fuente del código https://tdhock.github.io/blog/2023/dt-atime-figures/

El paquete mas sobreestimado

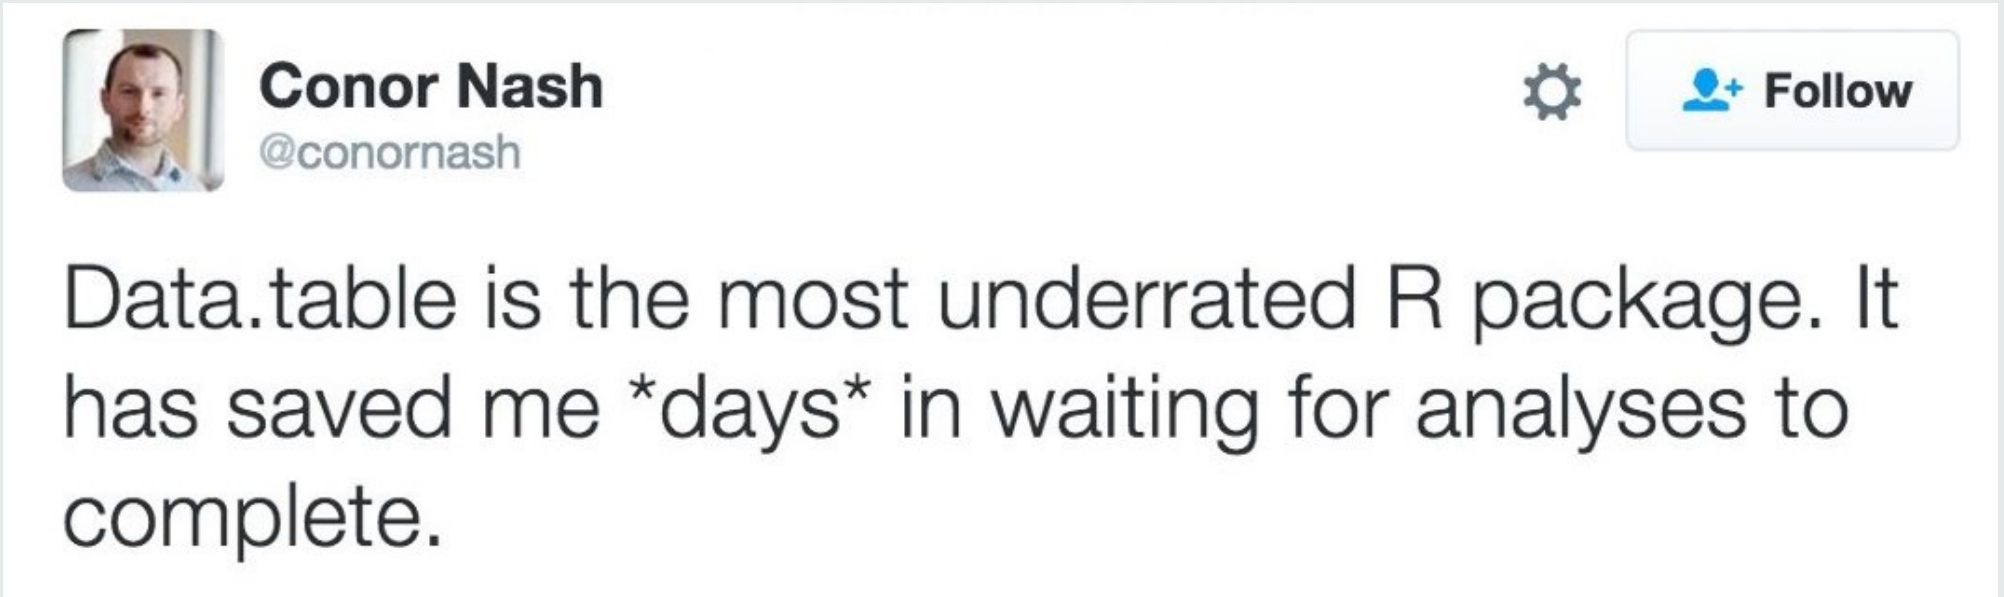

Data.table es el paquete R más subestimado. Me he ahorrado `días` esperando que se completen los análisis.

Poderoso

Alguien debería simplemente escribir una versión de data.table de **#Rstat** para **#python**, fin de la historia. No existe nada tan poderoso en este momento.

data.table data.table

Joey Reid
@JoeyPReid

data.table

Follow

data.table
data.table
data.table
data.table
ggplot2
rstan
knitr

#7FavPackages

Gran tristeza

Con gran tristeza me veo hoy forzada a usar data.table.

3/4 Usando data.table para análisis eficiente en bigdata

Instalando data.table, obtenemos PDF docs

- `Ejercicio:` instalar la versión de desarrollo desde GitHub, que contiene la más recientes características.
- Descargar *cheat sheet* http://ml.nau.edu/dtcheat.pdf
- Comenzando con R - edición tinyverse http://ml.nau.edu/tiny.pdf

>install.packages("remotes")
>remotes::install:github("Rdatatable/data.table")
(necesitas compilar: xcode para mac o rtools para windows)
o: si no tienes un compilador: instala desde CRAN el último update:

> install.packages("data.table")
> data.table::update_dev_pkg()

Creando data.table desde R objectos

- data.table(columna_nombre=columna_valor), como data.frame.
- valores en columnas cortas reciclados a lo largo de la columna más grande.

```
1 library(data.table)
```

```
1 data.table(
2   ID = c("b", "b","a", "a","c"),
3   a = 1:2,
4   b = 7,
5   c = 13:18)
```

```
      ID     a     b     c
   <char> <int> <num> <int>
1:      b     1     7    13
2:      b     2     7    14
3:      a     1     7    15
4:      a     2     7    16
5:      c     1     7    17
6:      b     2     7    18
```

data.table vs columnas frame

- Los nombres de las variables no sintácticas se mantienen de forma predeterminada.

```
1  head(data.table("10^8 m^3"=Nile, year=1871:1970))
```

```
   10^8 m^3  year
      <ts> <int>
1:     1120  1871
2:     1160  1872
3:      963  1873
4:     1210  1874
5:     1160  1875
6:     1160  1876
```

```
1  head(data.frame("10^8 m^3"=Nile, year=1871:1970))
```

```
  X10.8.m.3 year
1      1120 1871
2      1160 1872
3       963 1873
4      1210 1874
5      1160 1875
6      1160 1876
```

data.table vs columnas de listas de data.frame

```
1 data.table(L=list("scalar", c("vec","tor")),x=1:2)
```

```
        L     x
   <list> <int>
1:  scalar     1
2: vec,tor     2
```

```
1 data.frame(L=I(list("scalar", c("vec","tor"))),x=1:2)
```

```
        L x
1   scalar 1
2 vec, tor 2
```

Ejercicios

- `Tu turno`: convertí el conjunto de **datos::flores** en data table vía data.table.

- Crea un data.table con una fila, y columnas con los siguientes datos: tu nombre (*character*), años de experiencia con R (*numeric*), lugar de nacimiento(*character*), ciudad de residencia(*character*), idiomas(s) (*list of character*)

Lee CSV desde el archivo

- Vuelos de Nueva York (JFK, LGA o EWR) durante 2013.

```
#if(!file.exists("vuelos.csv"))download.file("https://ml.nau.edu/vuelos.csv
#  "vuelos.csv")
#(vuelos<-data.table::fread("vuelos.csv"))
```

```
    anio   mes   dia horario_salida salida_programada atraso_salida
   <int> <int> <int>          <int>             <int>         <num>
1:  2013     1     1            517               515             2
2:  2013     1     1            533               529             4
   horario_llegada llegada_programada atraso_llegada aerolinea vuelo
             <int>              <int>          <num>    <char> <int>
1:             830                819             11        UA  1545
2:             850                830             20        UA  1714
   codigo_cola origen destino tiempo_vuelo distancia  hora minuto
        <char> <char>  <char>        <num>     <num> <num>  <num>
1:      N14228    EWR     IAH          227      1400     5     15
2:      N24211    LGA     IAH          227      1416     5     29
            fecha_hora
                <POSc>
1: 2013-01-01 05:00:00
```

Lee CSV desde el comando shell

- Es útil con comandos que generan datos de salida en CSV (no archivos intermediarios)
- *egrep* es útil si no necesitas/o querés leer todo el conjunto de datos en R

```
data.table::fread("egrep 'LAX|anio'  vuelos.csv")
```

Ejercicio: Lee CSV desde URL

- Usualmente puede descargarse el archivo primero *download.file()*, para evitar tener que bajar de nuevo el archivo *re-starting R* Es conveniente.

- Llegó tu turno. Trata con el siguiente código:

vuelos <- data.table::fread(“http://ml.nau.edu/vuelos.csv”)

Subconjunto de filas usando i

- Piensa en términos básicos de unidades: filas, columnas, grupos.
- La sintaxis de data.table provee marcador de posición para cada uno de ellos.

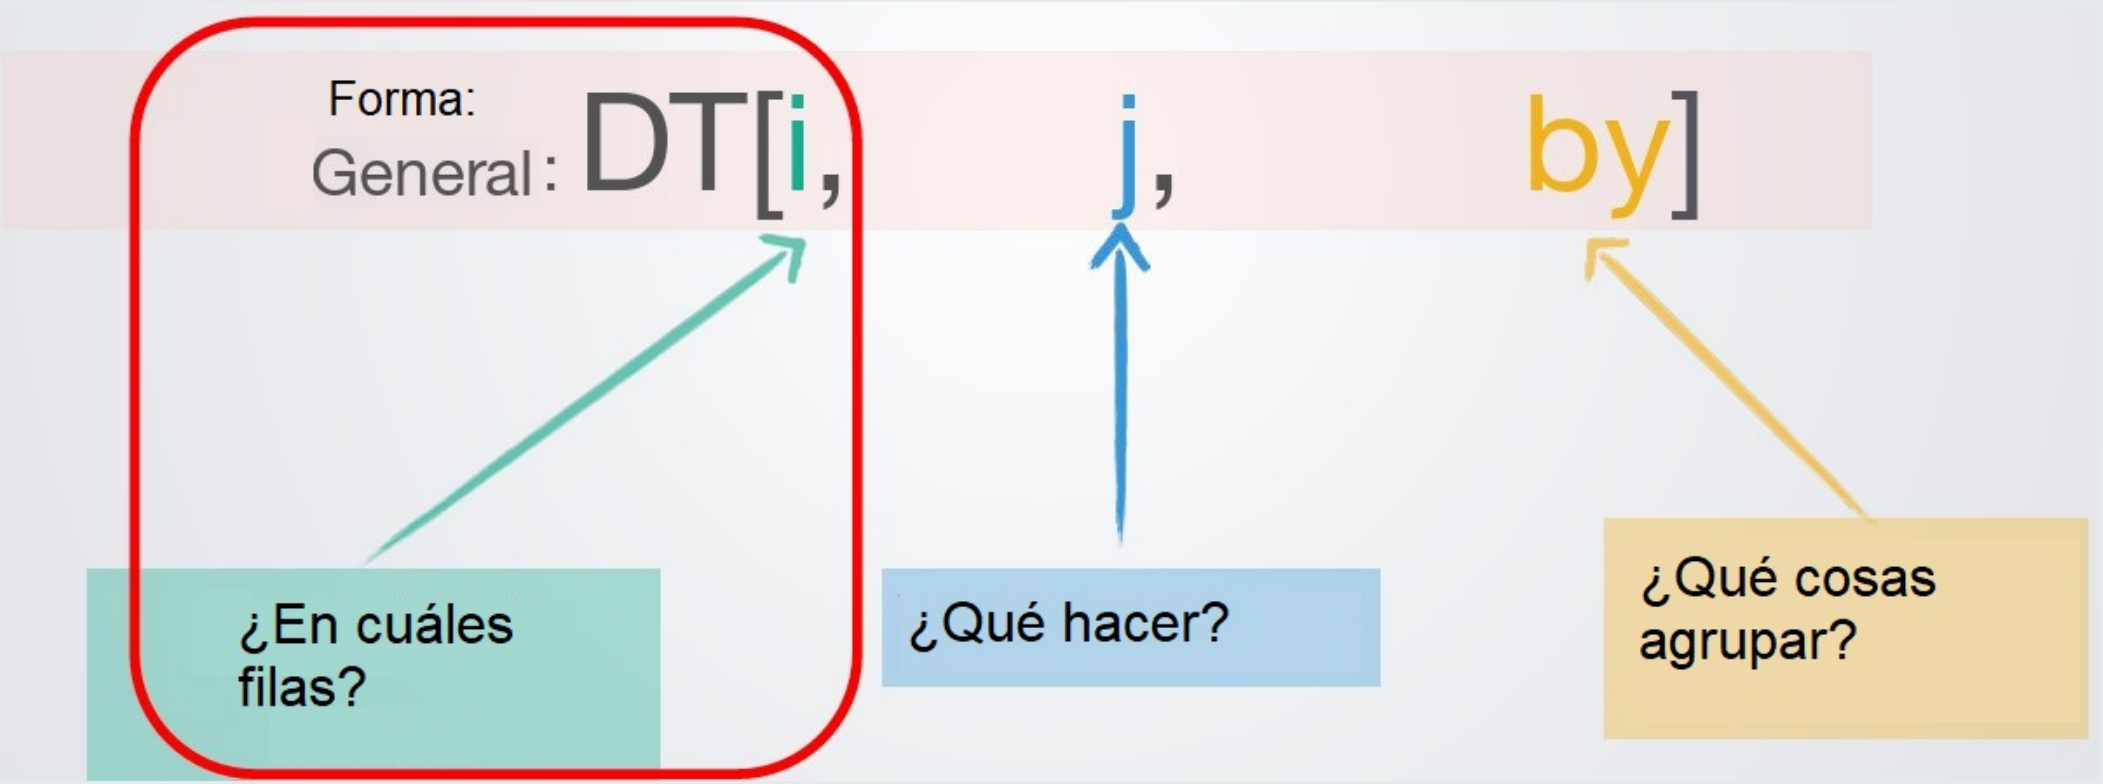

Subconjunto de filas lógicas

- Selecciona todos los vuelos con “JFK” del aeropuerto de origen en el mes de Junio.
- DT[rows,] la coma no es necesaria (pero permitida).

```
1  vuelos[origen == "JFK" & mes == 6]
```

```
    anio   mes   dia horario_salida salida_programada atraso_salida
   <int> <int> <int>          <int>             <int>         <num>
1:  2013     6     1              2              2359             3
2:  2013     6     1            538               545            -7
3:  2013     6     1            539               540            -1
   horario_llegada llegada_programada atraso_llegada aerolinea vuelo
             <int>              <int>          <num>    <char> <int>
1:              341                350             -9        B6   739
2:              925                922              3        B6   725
3:              832                840             -8        AA   701
   codigo_cola origen destino tiempo_vuelo distancia  hora minuto
        <char> <char>  <char>        <num>     <num> <num>  <num>
1:      N618JB    JFK     PSE          200      1617    23     59
2:      N806JB    JFK     BQN          203      1576     5     45
3:      N5EAAA    JFK     MIA          140      1089     5     40
            fecha_hora
                <POSc>
1: 2013-06-01 23:00:00
2: 2013-06-01 05:00:00
3: 2013-06-01 05:00:00
```

Conjunto de filas enteras

- Toma los primeros dos vuelos, o todos exceptuando el primero de los dos.
- Conjunto de enteros (*Integer*) en DT trabaja como en DF.

```
1  vuelos[1:2]
```

```
    anio   mes   dia horario_salida salida_programada atraso_salida
   <int> <int> <int>          <int>             <int>         <num>
1:  2013     1     1            517               515             2
   horario_llegada llegada_programada atraso_llegada aerolinea vuelo
             <int>              <int>          <num>    <char> <int>
1:             830                819             11        UA  1545
   codigo_cola origen destino tiempo_vuelo distancia  hora minuto
        <char> <char>  <char>        <num>     <num> <num>  <num>
1:      N14228    EWR     IAH          227      1400     5     15
           fecha_hora
               <POSc>
1: 2013-01-01 05:00:00
```

```
1  vuelos[-(1:1)]
```

```
    anio   mes   dia horario_salida salida_programada atraso_salida
   <int> <int> <int>          <int>             <int>         <num>
1:  2013     1     1            542               540             2
   horario_llegada llegada_programada atraso_llegada aerolinea vuelo
             <int>              <int>          <num>    <char> <int>
1:             923                850             33        AA  1141
   codigo_cola origen destino tiempo_vuelo distancia  hora minuto
        <char> <char>  <char>        <num>     <num> <num>  <num>
1:      N619AA    JFK     MIA          160      1089     5     40
           fecha_hora
```

Ordenar filas

- Ordena los vuelos primero por columna origen en orden ascendente, y luego por destino en orden descendentes.
- Ordena data.table de manera eficiente que se integre a la base R en 2016!

```
1  vuelos[order(origen, -destino)]
```

```
    anio   mes   dia horario_salida salida_programada atraso_salida
   <int> <int> <int>          <int>             <int>         <num>
1:  2013     1     2            905               822            43
2:  2013     1     3            848               850            -2
   horario_llegada llegada_programada atraso_llegada aerolinea vuelo
             <int>              <int>          <num>    <char> <int>
1:            1313               1045             NA        EV  4140
2:            1149               1113             36        EV  4125
   codigo_cola origen destino tiempo_vuelo distancia  hora minuto
        <char> <char>  <char>        <num>     <num> <num>  <num>
1:      N15912    EWR     XNA           NA      1131     8     22
2:      N21129    EWR     XNA          196      1131     8     50
            fecha_hora
                <POSc>
1: 2013-01-02 08:00:00
2: 2013-01-03 08:00:00
```

Ejercicios

- Tu turno. ¿Cuantas filas hay con **aerolinea** “AA” y **destino** “LAX”?
- Si ordenas la tabla. ¿Cuál es la primer fecha y ultima mes/dia/hora?

- Una pista: puedes usar DT[…][…] en una cadena.
Similar para *piping*, DF |>…|>…

Computa columnas in j

- Piensa en términos básicos de unidades:filas, columnas,grupos
- La sintaxis de data.table provee Marcador de posición para cada una de ellas.

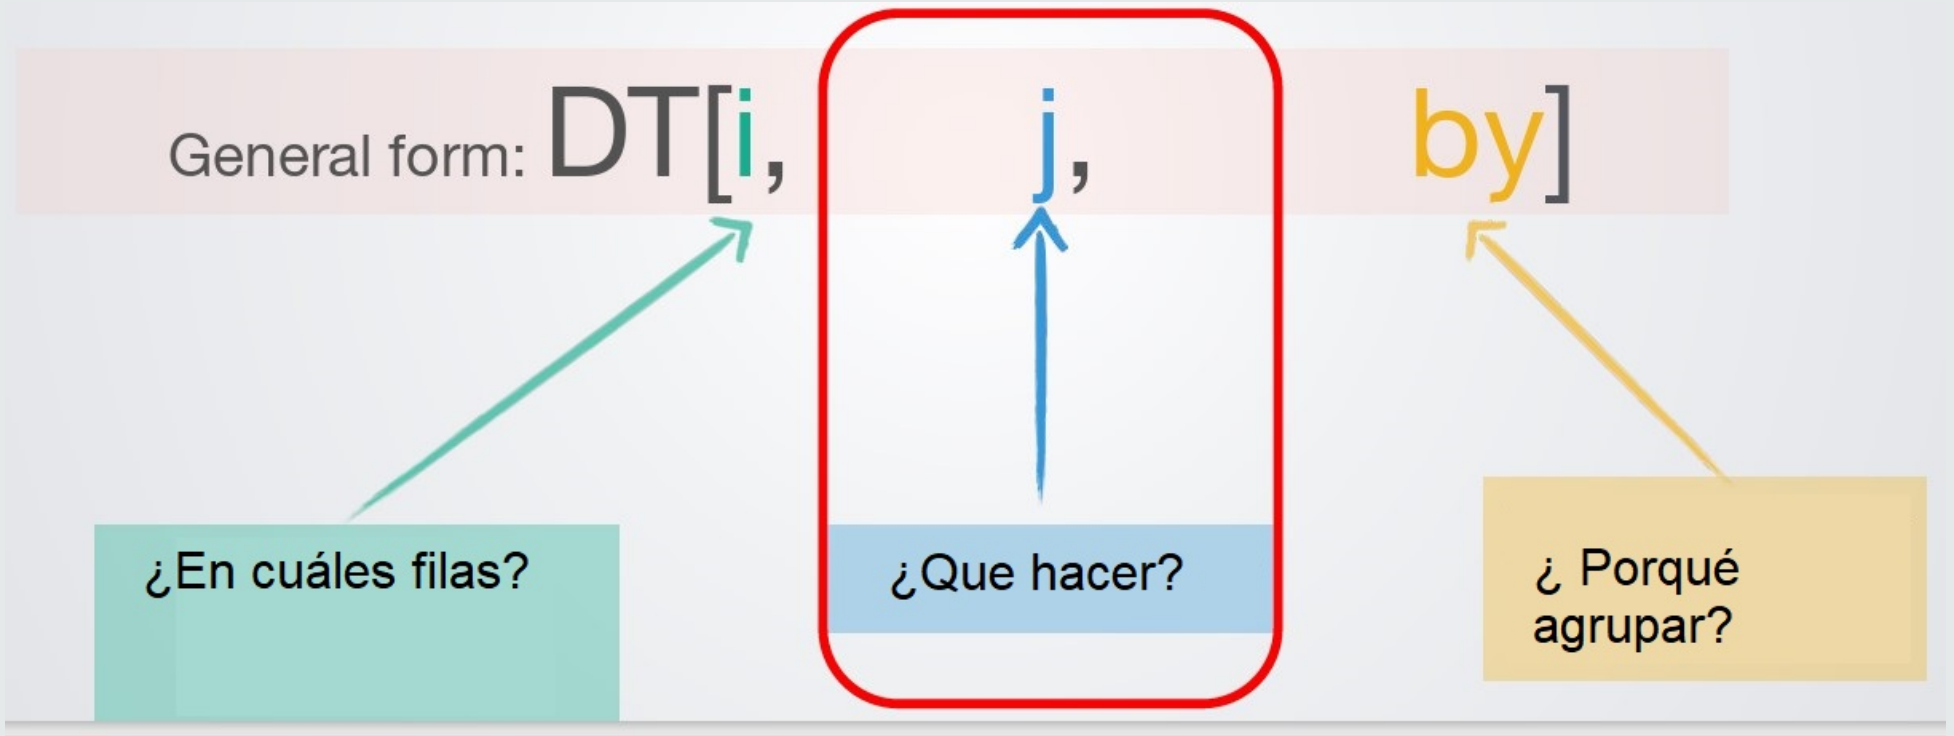

Select una columna

- DT[,“atraso_llegada”] -> data.table con una columna.
- DT[,“atraso_llegada”] -> vector
  como DT$atraso_llegada o DT[[“atraso_llegada”]] en base a R
- **Ejercicio:** usa hist() para dibujar un histograma de atrasos de llegada.

```
1  str(vuelos[, "atraso_llegada" ])
```

```
Classes 'data.table' and 'data.frame':  336776 obs. of  1 variable:
 $ atraso_llegada: num  11 20 33 -18 -25 12 19 -14 -8 8 ...
 - attr(*, ".internal.selfref")=<externalptr>
```

```
1  str(vuelos[, "atraso_llegada"]) # como DT[["atraso_llegada"]] o DT$atraso_llegada
```

```
Classes 'data.table' and 'data.frame':  336776 obs. of  1 variable:
 $ atraso_llegada: num  11 20 33 -18 -25 12 19 -14 -8 8 ...
 - attr(*, ".internal.selfref")=<externalptr>
```

Select 2 columnas con literal

- Si data.table/list/. es usada en j, entonces un data.table se retorna.
- También puedes usar c(“name”) en j

```
1  vuelos[, data.table(atraso_llegada, atraso_salida)]
```

```
   atraso_llegada atraso_salida
            <num>         <num>
1:             11             2
2:             20             4
3:             33             2
```

```
1  vuelos[, c("atraso_llegada", "atraso_salida")]
```

```
   atraso_llegada atraso_salida
            <num>         <num>
1:             11             2
2:             20             4
3:             33             2
```

Select 2 col. c/variable

- Puedes usar con=FALSE o double dot `..` (como un nivel arriba de la ruta del archivo, busca por *select_cols* en el ambiente no como un nombre de columna)

```
(DT=data.table(x=1:2, y=3:4,select_cols=c("foo", "bar")))
```

```
   x     y select_cols
<int> <int>      <char>
1:     1     3         foo
2:     2     4         bar
```

```
select_cols=c("x", "y")
DT[, select_cols]
```

```
[1] "foo" "bar"
```

```
DT[,..select_cols]
```

```
   x     y
<int> <int>
1:     1     3
2:     2     4
```

```
DT[, select_cols, with=FALSE]
```

```
   x     y
<int> <int>
1:     1     3
2:     2     4
```

Select todas excepto dos

- Puedes usar ambos `!` o `-` para negar la selección de columnas.

```
1 retrasos_cols= c("atraso_llegada", "atraso_salida")
2 head(vuelos[, !..retrasos_cols])
```

```
    anio   mes   dia horario_salida salida_programada horario_llegada
   <int> <int> <int>          <int>              <int>           <int>
1:  2013     1     1            517                515             830
2:  2013     1     1            533                529             850
   llegada_programada aerolinea vuelo codigo_cola origen destino tiempo_vuelo
                <int>    <char> <int>      <char> <char>  <char>        <num>
1:                819        UA  1545      N14228    EWR     IAH          227
2:                830        UA  1714      N24211    LGA     IAH          227
   distancia  hora minuto           fecha_hora
       <num> <num>  <num>               <POSc>
1:      1400     5     15 2013-01-01 05:00:00
2:      1416     5     29 2013-01-01 05:00:00
```

```
1 head(vuelos[, -..retrasos_cols])
```

```
    anio   mes   dia horario_salida salida_programada horario_llegada
   <int> <int> <int>          <int>              <int>           <int>
1:  2013     1     1            517                515             830
2:  2013     1     1            533                529             850
   llegada_programada aerolinea vuelo codigo_cola origen destino tiempo_vuelo
                <int>    <char> <int>      <char> <char>  <char>        <num>
1:                819        UA  1545      N14228    EWR     IAH          227
2:                830        UA  1714      N24211    LGA     IAH          227
   distancia  hora minuto           fecha_hora
       <num> <num>  <num>               <POSc>
1:      1400     5     15 2013-01-01 05:00:00
2:      1416     5     29 2013-01-01 05:00:00
```

Select rangos de columnas

- Puedes usar `col1:col2` -ambas- o todas (negativo `!` o `-`)

```
1 head(vuelos[, anio:dia])
```

```
    anio   mes   dia horario_salida salida_programada atraso_salida
   <int> <int> <int>          <int>              <int>          <num>
1:  2013     1     1            517                515              2
2:  2013     1     1            533                529              4
   horario_llegada llegada_programada atraso_llegada aerolinea vuelo
             <int>              <int>          <num>    <char> <int>
1:              830                819             11        UA  1545
2:              850                830             20        UA  1714
   codigo_cola origen destino tiempo_vuelo distancia  hora minuto
        <char> <char>  <char>        <num>     <num> <num>  <num>
1:      N14228    EWR     IAH          227      1400     5     15
2:      N24211    LGA     IAH          227      1416     5     29
            fecha_hora
                <POSc>
1: 2013-01-01 05:00:00
2: 2013-01-01 05:00:00
```

Select rangos de columnas

```
1 head(vuelos[, !(anio:dia)])
```

```
1 print(vuelos[1:2, ])
```

```
    anio   mes   dia horario_salida salida_programada atraso_salida
   <int> <int> <int>          <int>              <int>          <num>
1:  2013     1     1            517                515              2
2:  2013     1     1            533                529              4
   horario_llegada llegada_programada atraso_llegada aerolinea vuelo
             <int>              <int>          <num>    <char> <int>
1:              830                819             11        UA  1545
2:              850                830             20        UA  1714
   codigo_cola origen destino tiempo_vuelo distancia  hora minuto
        <char> <char>  <char>        <num>     <num> <num>  <num>
1:      N14228    EWR     IAH          227      1400     5     15
2:      N24211    LGA     IAH          227      1416     5     29
            fecha_hora
                <POSc>
1: 2013-01-01 05:00:00
2: 2013-01-01 05:00:00
```

Rename y compute las columnas

- **Ejercicio**: trata de usar `.()` o `list()` en vez de data.table() en j
- .() es un alias de list() los items en listas son columnas de la tabla.

```
1  vuelos[, data.table(puntodestino=destino, aire_horas=tiempo_vuelo/60)]
```

```
        puntodestino aire_horas
              <char>      <num>
     1:          IAH   3.783333
     2:          IAH   3.783333
     3:          MIA   2.666667
     4:          BQN   3.050000
     5:          ATL   1.933333
    ---
336772:          DCA         NA
336773:          SYR         NA
336774:          BNA         NA
336775:          CLE         NA
336776:          RDU         NA
```

Resume todas las filas

vuelos[, .(m_arr = mean(atraso_llegada), m_dep = mean(atraso_salida))]

vuelos[, .(rango_llegada = range(atraso_llegada), stat=c(“min”,“max”))]

- En `data.table/list/.` en j, resume funciones que pueden usarse.
- En este caso podemos usar `mean`, con retorno de un número simple.
- Podemos también usar `range`, con la cual retorna dos números.
- Podemos computar `mean`, `min` ,`max` de arribos y partidas de todos los vuelos.
- Ejercicio: computa min/max **tiempo_vuelo** y **distancia**

Crea/elimina columnas en j

- Piensa en términos básicos de unidades: filas, columnas,grupos.
- Podemos usar DT[, variable:= valor] o set(DT, j="variable", valor=valor)

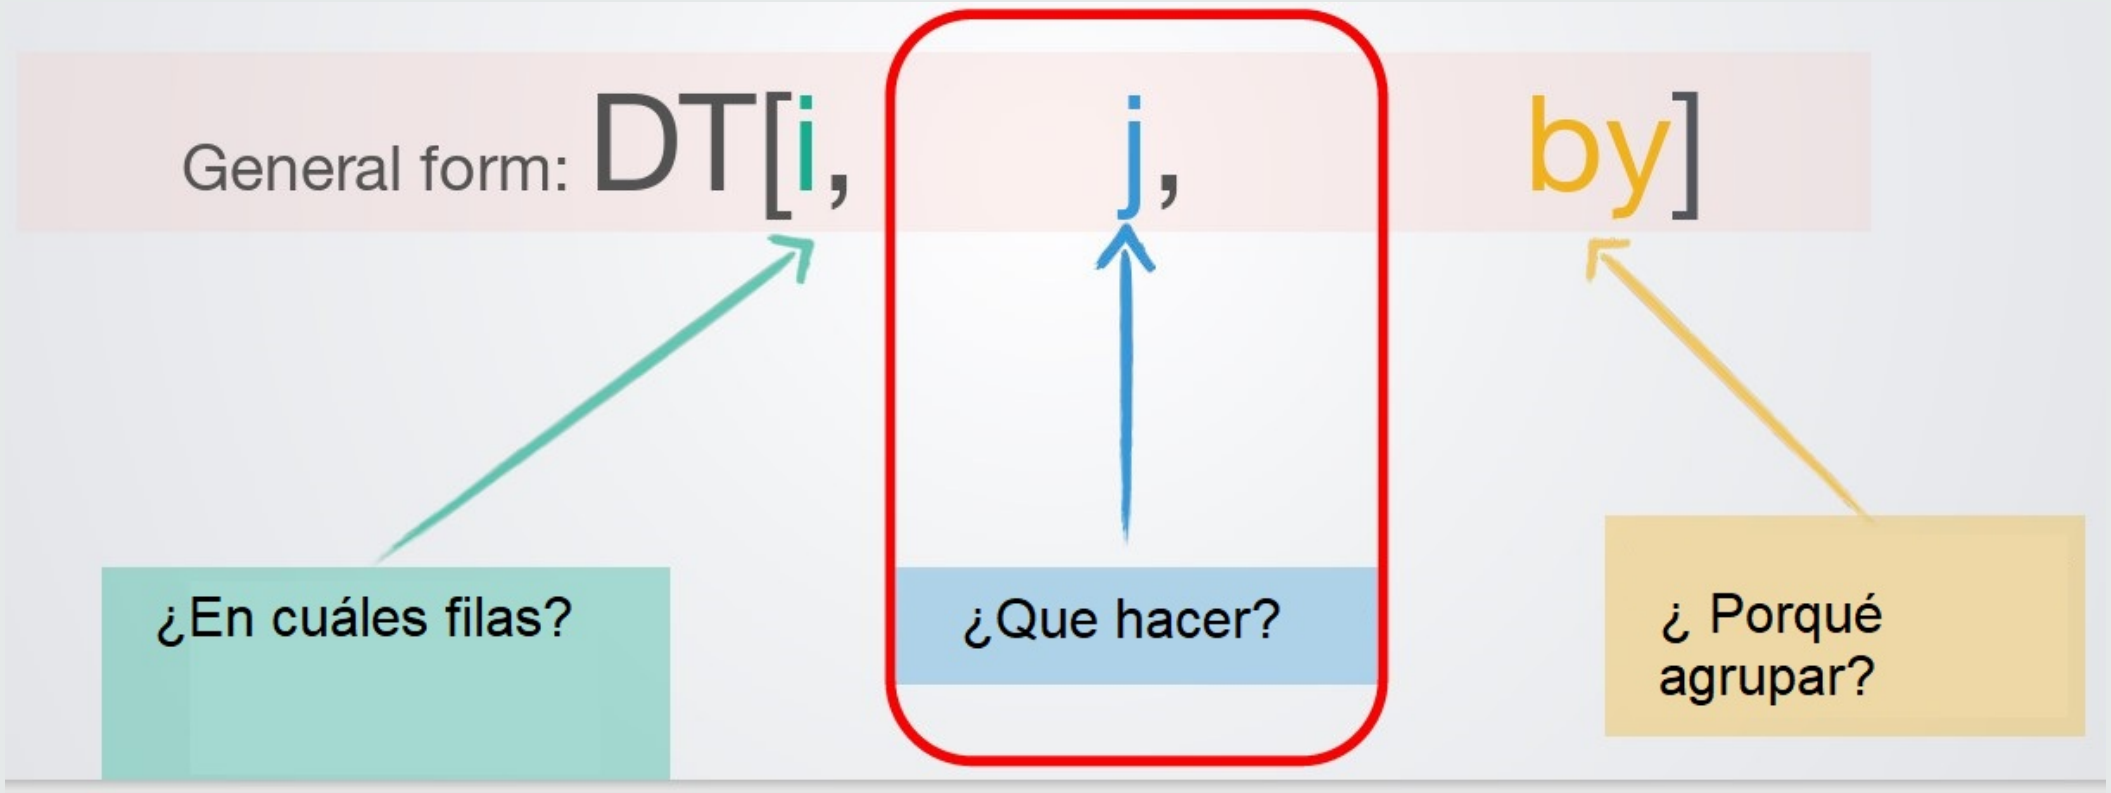

Comparando columnas en base a R en data.table

- En la columna denominada “mundo” establece el valor de “hola”
- Es posible utilizar código base R con data.table.
- Históricamente, := ha sido más eficiente en (tiempo/memoria)
- Recientes versiones de R lo han mejorado enormemente!

	Base código R	**código data.table**
Literal	DF$mundo <- “Hola”	DT[, mundo := “hola”]
Variable	DF[mi_var_nombre]] <- “Hola”	set(DT,j=my_var_nombre, value=“Hola”)

Crear valor en las columnas:=

- DT[, variable := valor] puede usarse para crear nuevas columnas o updates.
- Mismo efecto que DT$variable <- valor, o DT[["variable"]] <- valor

```
1 mes.dt <- vuelos[, .(mes, tiempo_vuelo, distancia)]
```

```
1 head(mes.dt)
```

```
    mes tiempo_vuelo distancia
   <int>        <num>     <num>
1:     1          227      1400
2:     1          227      1416
3:     1          160      1089
4:     1          183      1576
5:     1          116       762
6:     1          150       719
```

```
1 mes.dt[, aire_horas := tiempo_vuelo/60]
```

```
1 head(mes.dt)
```

```
    mes tiempo_vuelo distancia aire_horas
   <int>        <num>     <num>      <num>
1:     1          227      1400   3.783333
2:     1          227      1416   3.783333
3:     1          160      1089   2.666667
4:     1          183      1576   3.050000
5:     1          116       762   1.933333
6:     1          150       719   2.500000
```

Elimina columnas := NULL

- DT[, variable :=NULL] elimina columnas
- Todas := las operaciones son por referencias (eficiente)

```
1 head(mes.dt)
```

```
    mes tiempo_vuelo distancia aire_horas
  <int>        <num>     <num>      <num>
1:     1          227      1400   3.783333
2:     1          227      1416   3.783333
3:     1          160      1089   2.666667
4:     1          183      1576   3.050000
5:     1          116       762   1.933333
6:     1          150       719   2.500000
```

```
1 mes.dt[, tiempo_vuelo := NULL]
```

```
1 head(mes.dt)
```

```
    mes distancia aire_horas
  <int>     <num>      <num>
1:     1      1400   3.783333
2:     1      1416   3.783333
3:     1      1089   2.666667
4:     1      1576   3.050000
5:     1       762   1.933333
6:     1       719   2.500000
```

set()crea/elimina columnas

- set(DT, j="col_name", value=col_val) es igual que DT[, col_name :=col_val]
- Usualmente cuando los nombres de las columnas estan almacenados en una variable:

```
my_var_name = "nuevita"
set(vuelos, j=my_var_name,
    value="HOLA!")
my_var_name
```

```
[1] "nuevita"
```

```
print(vuelos[1:1, ])
```

```
    anio   mes   dia horario_salida salida_programada atraso_salida
   <int> <int> <int>          <int>              <int>         <num>
1:  2013     1     1            517                515             2
   horario_llegada llegada_programada atraso_llegada aerolinea vuelo
             <int>              <int>          <num>    <char> <int>
1:              830                819             11        UA  1545
   codigo_cola origen destino tiempo_vuelo distancia  hora minuto
        <char> <char>  <char>        <num>     <num> <num>  <num>
1:      N14228    EWR     IAH          227      1400     5     15
            fecha_hora nuevita
                <POSc>  <char>
1: 2013-01-01 05:00:00   HOLA!
```

Elimina Columnas

set(vuelos, j=my_var_name, value= NULL)

Ejercicios

- Crea nuevas columnas aire_horas := tiempo_vuelo/60 como en las diapositivas previas.
- Crea una nueva columna hora_llegada := + aire_horas
- Usa vuelos[, range(horas)] para encontrar el rango normal de la variable hora.
- Hace un subconjunto para encontrar cuantas filas tienen hora_llegada > max(hora)
- Crea una nueva variable dia_llegada con la cual sea “same” or “next” ifelse(hora_llegada>max(horas), “next”, “same”)

Computa subconjunto con iyj

- Piensa en términos básicos de unidades: filas, columnas, grupos.
- La sintaxis de data.table da un lugar para cada uno.

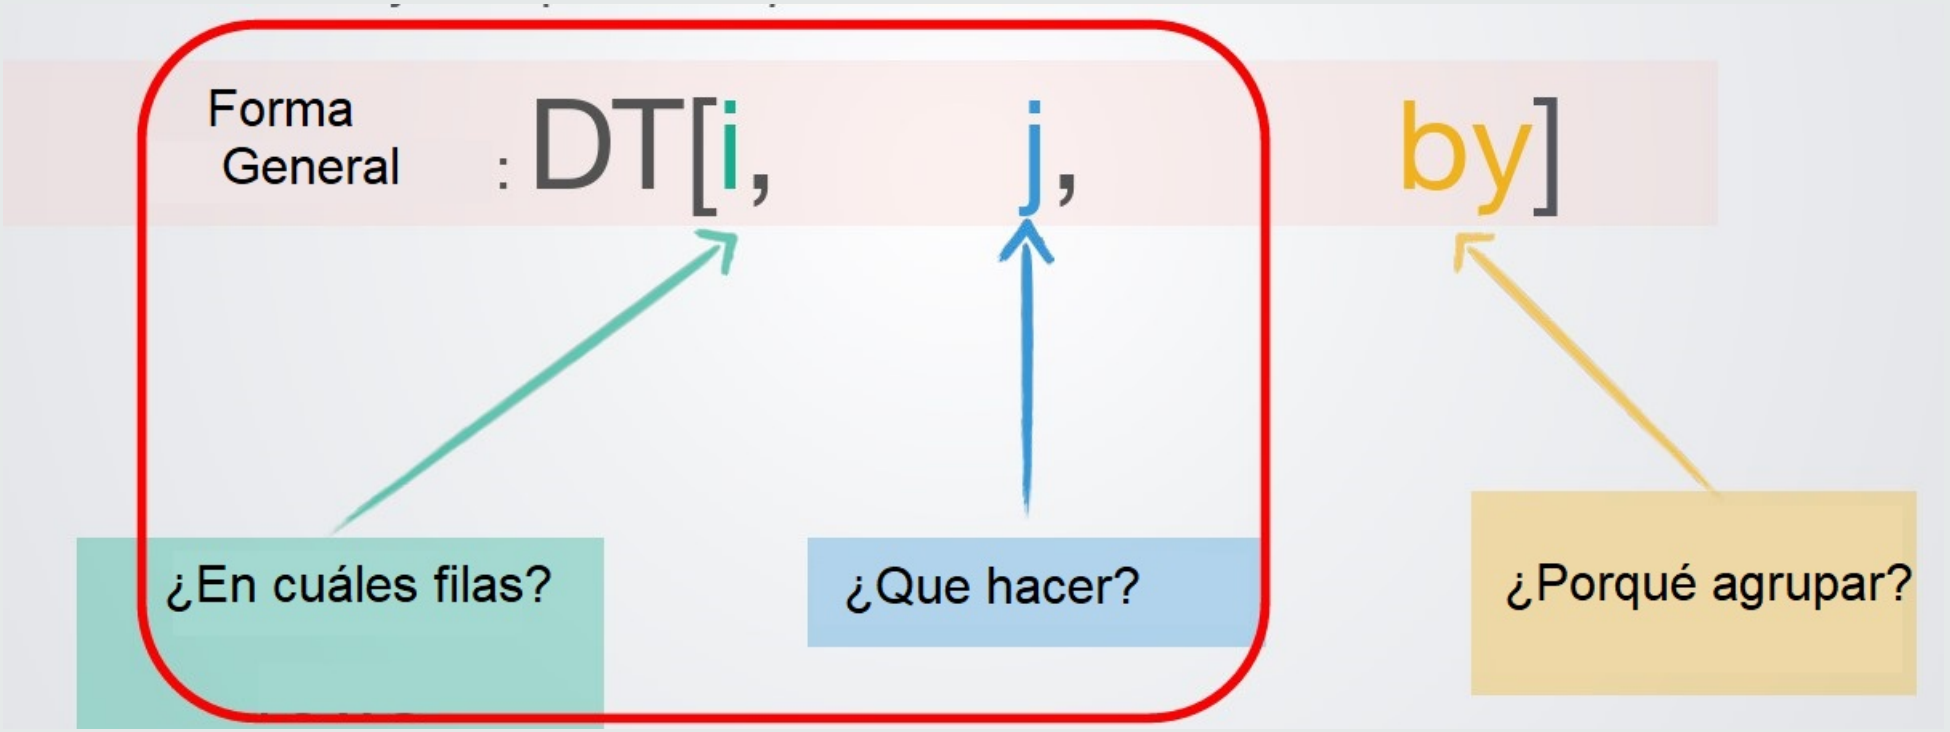

Resumiendo un subconjunto de filas

```
  1  vuelos[origen == "JFK" & mes == 6L, length(destino)]
```

```
[1] 9472
```

```
  1  vuelos[origen == "JFK" & mes == 6L, .N]
```

```
[1] 9472
```

```
  1  vuelos[origen == "JFK" & mes == 6L, .(m_llegada=mean(atraso_llegada), num_vuelos=.N)]
```

```
   m_llegada num_vuelos
       <num>      <int>
1:        NA       9472
```

- ¿Cuántos viajes se realizaron desde el año 2013 desde el aeropuerto de “JFK” en el mes de junio y cual es el promedio de partidas y retraso en la llegada ?
- Especial símbolo .N puede usarse en [] para tener los números de las filas.
- Ejercicio: para todos los vuelos con positivas partidas, ¿Cuál fue el promedio *mean* de demora en las llegadas? y ¿Para vuelos con negativas partidas?

Update columnas con:=

- DT[i , variable := value] se puede utilizar para actualizar filas que coinciden con i
- set(DT, i= , j="variable", value=) útil para programar

```
1  head(mes.dt)
```

```
     mes distancia aire_horas
   <int>     <num>       <num>
1:     1      1400   3.783333
2:     1      1416   3.783333
3:     1      1089   2.666667
4:     1      1576   3.050000
5:     1       762   1.933333
6:     1       719   2.500000
```

```
1  mes.dt[distancia<100, aire_horas := 0]
```

```
1  head(mes.dt)
```

```
     mes distancia aire_horas
   <int>     <num>       <num>
1:     1      1400   3.783333
2:     1      1416   3.783333
3:     1      1089   2.666667
4:     1      1576   3.050000
5:     1       762   1.933333
6:     1       719   2.500000
```

Ejercicios

- Continúa de previos ejercicios…
- Crea nuevas columnas `horas_aire := tiempo_vuelo/60` como las diapositivas previas.
- crea una nueva columna `horas_llegada := hora + horas_aire`.
- Crea una nueva columna `dia_llegada` de la cual sea ambos iguales o siguientes `ifelse(horas_llegada>max(hora), "next", "same")`
- Actualiza horas_llegada :=`horas_llegadas-24` para las filas con `horas_llegadas > 24` .
- Usa vuelos`[, range(horas_llegada)]` para confirmar el valor entre 0 y 24.

Computa por c/grupo j y by

- Piensa en términos básicos de unidades: filas, columnas, grupos.
- La sintaxis de data.table provee un lugar para cada uno de ellos.

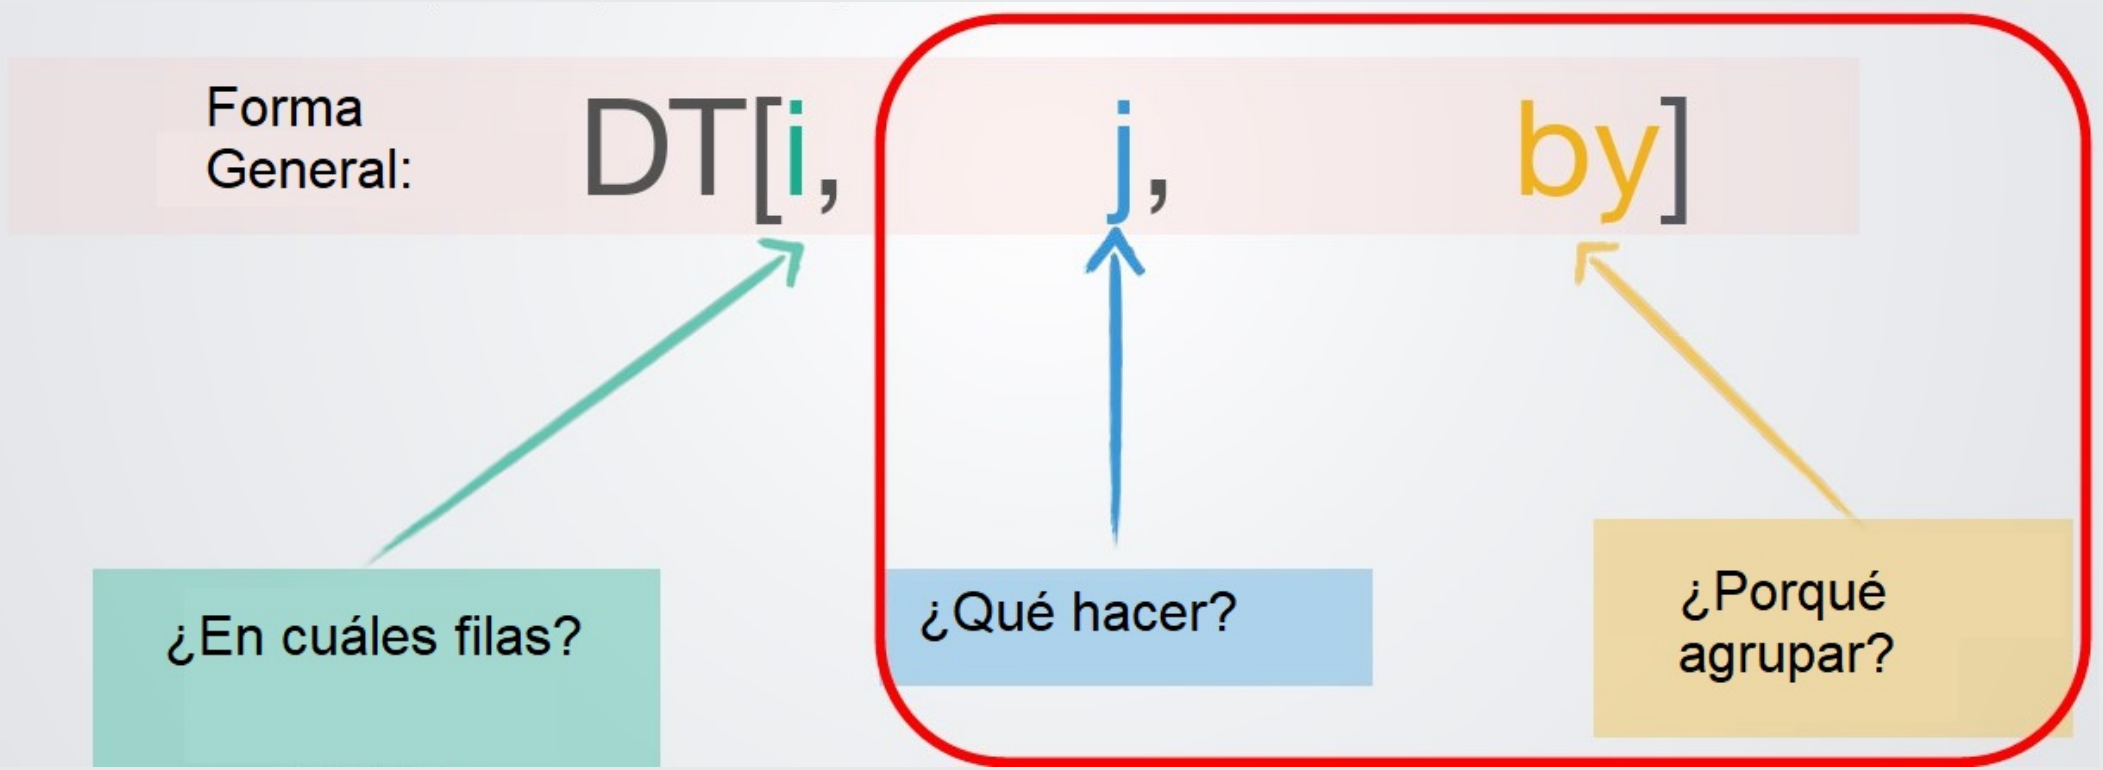

Resumiendo por cada grupo

- by=origen significa tratar a cada único valor de origen como un grupo.
- Por cada grupo/origen, podemos computar el número de vuelos y el promedio *mean* de los arribos y partidas.

```
1  vuelos[, .(num_vuelos=.N), by=origen]
```

```
   origen num_vuelos
   <char>      <int>
1:    EWR     120835
2:    LGA     104662
3:    JFK     111279
```

```
1  vuelos[, .(num_vuelos=.N, mean_retraso_llegada=mean(atraso_llegada)),
2          by=origen]
```

```
   origen num_vuelos mean_retraso_llegada
   <char>      <int>                <num>
1:    EWR     120835                   NA
2:    LGA     104662                   NA
3:    JFK     111279                   NA
```

Resumiendo por cada grupo

- Muchas variables pueden especificarse vía *.() en by* lo que significa usar cada combinación única para todas las variables como un grupo.

```
1 vuelos[, .(num_vuelos=.N, mean_retraso_llegada=mean(atraso_llegada)),
2          by=.(origen, destino)]
```

```
    origen destino num_vuelos mean_retraso_llegada
    <char>  <char>      <int>                <num>
 1:    EWR     IAH       3973                   NA
 2:    LGA     IAH       2951                   NA
 3:    JFK     MIA       3314                   NA
 4:    JFK     BQN        599                   NA
 5:    LGA     ATL      10263                   NA
---
220:    LGA     TVC         77                   NA
221:    LGA     MYR          3                 -3.0
222:    EWR     TVC         24                   NA
223:    EWR     ANC          8                 -2.5
224:    EWR     LGA          1                   NA
```

Nuevo by/gruping variables

```
vuelos[, .(
  num_vuelos=.N,
  mean_retraso_llegada=mean(atraso_llegada)
), by=.(
  origen=tolower(origen),
  destino.punt=destino
)]
```

```
    origen destino.punt num_vuelos mean_retraso_llegada
    <char>       <char>      <int>                <num>
 1:    ewr          IAH       3973                   NA
 2:    lga          IAH       2951                   NA
 3:    jfk          MIA       3314                   NA
 4:    jfk          BQN        599                   NA
 5:    lga          ATL      10263                   NA
---
220:    lga          TVC         77                   NA
221:    lga          MYR          3                 -3.0
222:    ewr          TVC         24                   NA
223:    ewr          ANC          8                 -2.5
224:    ewr          LGA          1                   NA
```

- Las variables pueden renombrarse al computarse.
- Ejercicio: para todos los vuelos con retraso de salida positiva o negativa cual fue el promedio *mean* de las demoras de los arribos? Ayuda: usa sign(atraso_salida) en by.

Usando los tres argumentos juntos

- Piensa en términos básicos de unidades: filas, columnas, grupos.
- La sintaxis de data.table provee un lugar para cada uno de ellos.

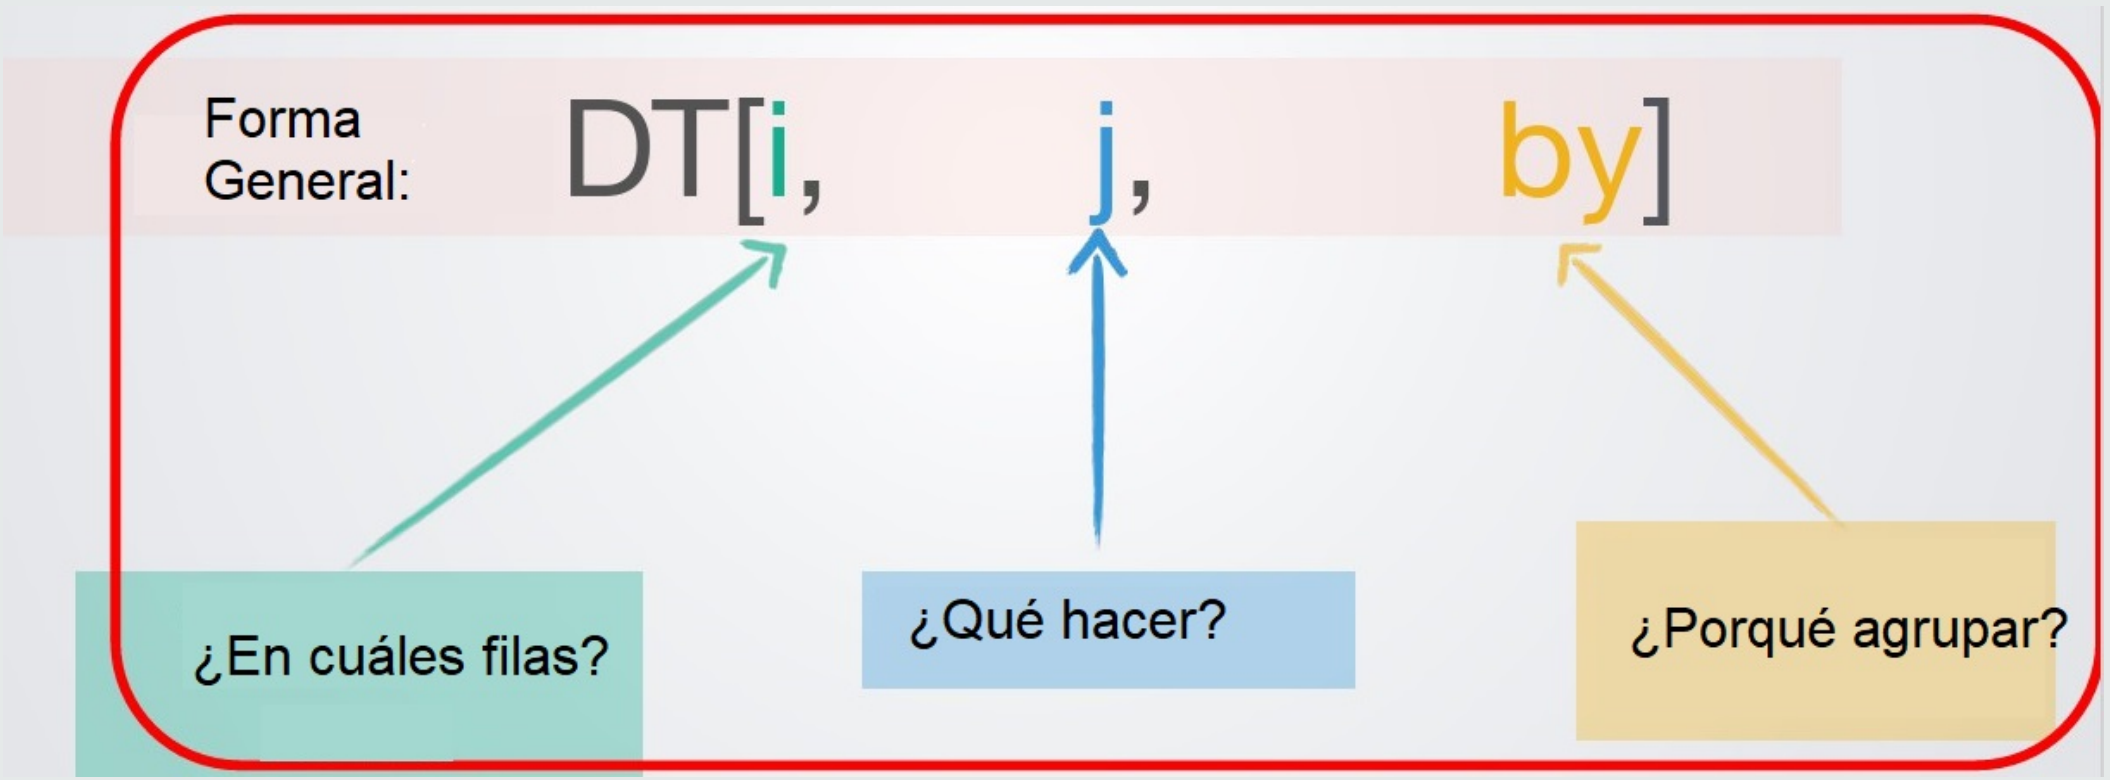

Subconjunto de filas antes de resumir

- i puede ser usada en el mismo tiempo que `j` y `by`.
- Para el subconjunto de vuelos con AA como **aerolínea**, por cada origen y destino, obtén el número de vuelos, y el promedio *mean* de arribos demorados.

```
1  vuelos[aerolinea=="AA", .(num_vuelos=.N, mean_retraso_llegada=mean(atraso_llegada)), by=.(origen, destino)]
```

```
   origen destino num_vuelos mean_retraso_llegada
   <char>  <char>      <int>                <num>
1:    JFK     MIA       2221                   NA
2:    LGA     ORD       5694                   NA
3:    LGA     DFW       4836                   NA
4:    EWR     MIA       1068                   NA
5:    LGA     MIA       3945                   NA
```

DT[i] dentro de j con by

- Para cada grupo, definido con un único valor de origen y destino, selecciona la primer fila, y las columnas tiempo_vuelo, distancia.
- Ayuda: .() es sinónimo de list(), por lo que data.table() debe ser usado aquí.

```
1 vuelos[, data.table(tiempo_vuelo, distancia) [1] , by=.(origen,destino)]
```

```
    origen destino tiempo_vuelo distancia
    <char>  <char>        <num>     <num>
  1:    EWR     IAH          227      1400
  2:    LGA     IAH          227      1416
  3:    JFK     MIA          160      1089
  4:    JFK     BQN          183      1576
  5:    LGA     ATL          116       762
 ---
220:    LGA     TVC          101       655
221:    LGA     MYR           74       563
222:    EWR     TVC           93       644
223:    EWR     ANC          418      3370
224:    EWR     LGA           NA        17
```

SD[i] dentro de j con by

- Para cada grupo, definido de valores únicos de origen y destino, selecciona la primer fila, y todas las columnas.
- Ayuda: .SD es un data.table; lo que significa "subconjunto de datos" para un grupo.

```
1  vuelos[, .SD[1], by=.(origen,destino)]
```

```
   origen destino  anio   mes   dia horario_salida salida_programada
   <char>  <char> <int> <int> <int>          <int>              <int>
1:    EWR     IAH  2013     1     1            517                515
2:    LGA     IAH  2013     1     1            533                529
3:    JFK     MIA  2013     1     1            542                540
   atraso_salida horario_llegada llegada_programada atraso_llegada aerolinea
           <num>           <int>               <int>          <num>    <char>
1:             2             830                 819             11        UA
2:             4             850                 830             20        UA
3:             2             923                 850             33        AA
   vuelo codigo_cola tiempo_vuelo distancia  hora minuto          fecha_hora
   <int>      <char>        <num>     <num> <num>  <num>              <POSc>
1:  1545      N14228          227      1400     5     15 2013-01-01 05:00:00
2:  1714      N24211          227      1416     5     29 2013-01-01 05:00:00
3:  1141      N619AA          160      1089     5     40 2013-01-01 05:00:00
   nuevita
    <char>
1:   HOLA!
2:   HOLA!
3:   HOLA!
```

.SD[i] dentro de j con by

- Ejercicio: por cada origen y destino, obtiene la **última fila**.

Ayuda: recordá que .N significa el número de filas en una tabla.

- Ejercicio: por cada origen y destino, obtené la **primer y última fila**.

Escribir/leer CSV en piezas

- Piensa en términos básicos de unidades: filas, columnas, grupos.
- La sintaxis de data.table provee un lugar para cada uno.

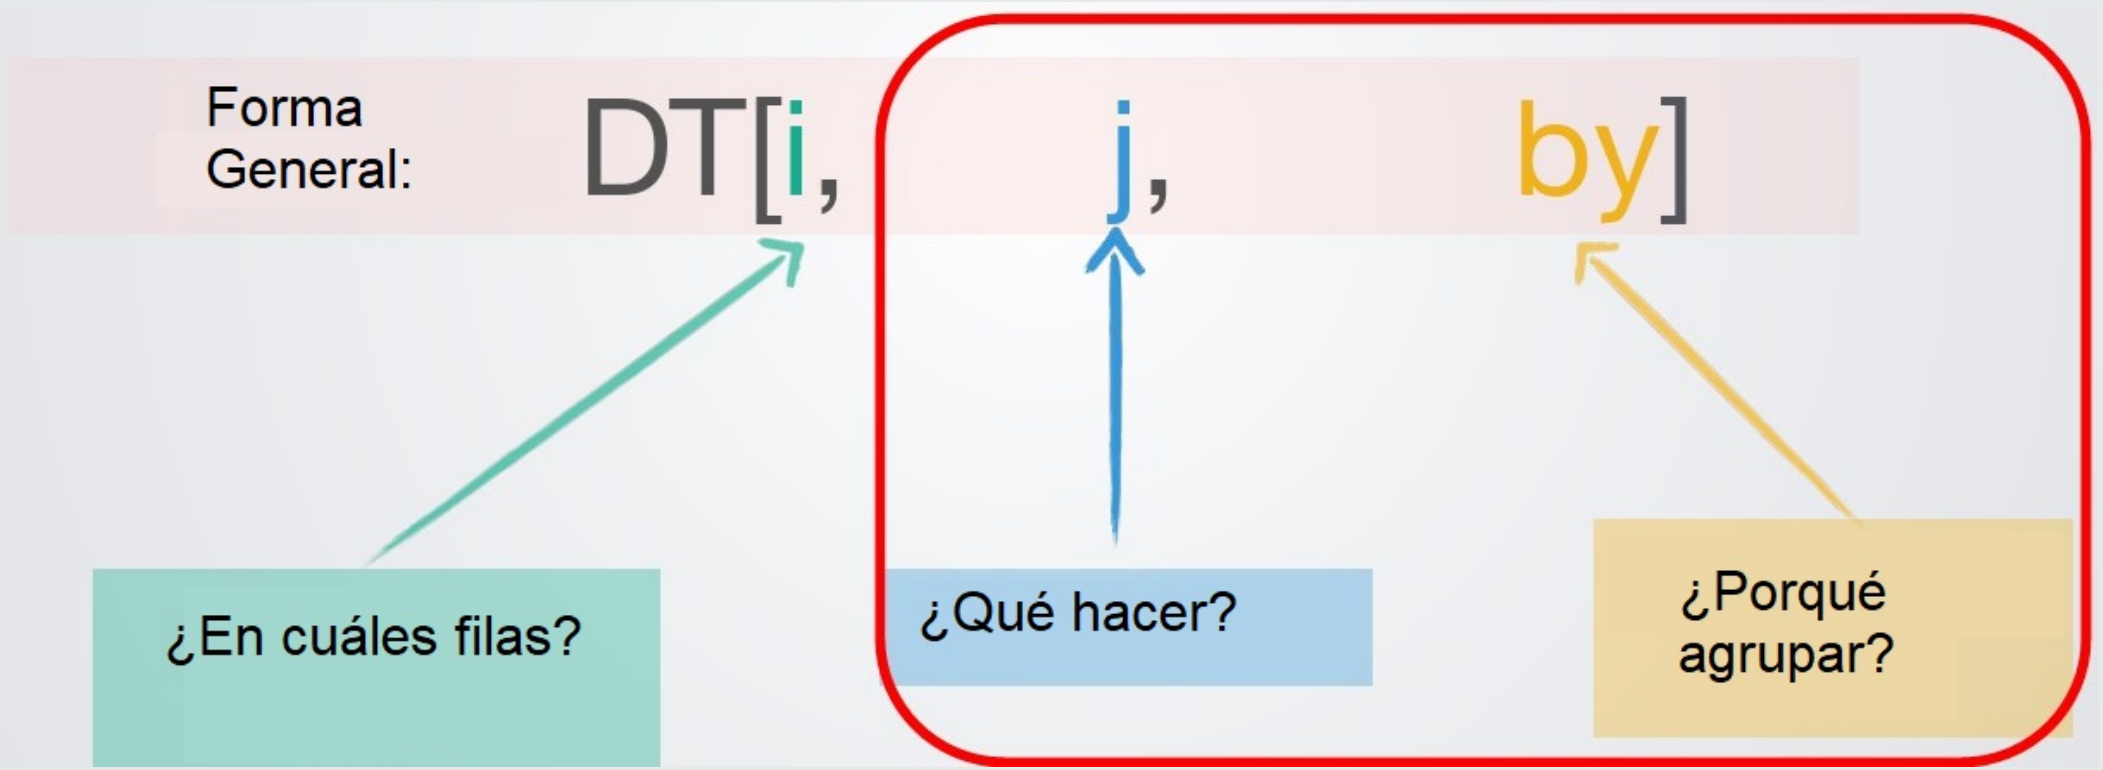

fwrite - escribe eficiente csv

-Escribe el data set completo de vuelos a un disco.

fwrite(vuelos, “vuelos.csv”)

DT[, j=fwrite(), by=variable]

- Escribe una fila por mes, 1.csv, 2.csv, etc.
- by= mes significa que en j, mes es escalable, por lo que paste0 (mes, ".csv") puede ser usado para crear 1.csv, 2.csv, etc.

```
vuelos[, fwrite(
   data.table(tiempo_vuelo, distancia),
   paste0(mes,".csv")
   ), by=mes]
```

```
Empty data.table (0 rows and 1 cols): mes
```

```
 Sys.glob("*.csv")
```

```
 [1] "1.csv"  "10.csv" "11.csv" "12.csv" "2.csv"  "3.csv"  "4.csv"  "5.csv"
 [9] "6.csv"  "7.csv"  "8.csv"  "9.csv"
```

fread CSV, combinado con rbindlist

- (1)inicialmente lista vacía, (2) en cada iteración del bucle for, asigna una tabla con un elemento de la lista, (3) rbindlist para crear una tabla simple con todos los datos.

```
mes.dt.list <- list()
```

```
#(2)
for(mes.csv in Sys.glob("*.csv")){
  mes<- sub(".csv", "", mes.csv)
  mes.dt.list[[mes.csv]] <- data.table(mes,fread(mes.csv))}

#(3)  (mes.dt <- data.table::rbindlist(mes.dt.list))
```

Lee muchos CSV usando by

- by=mes.csv significa computar `j=fread(mes.csv)` por cada único valor de mes.csv (por cada archivo CSV)
- Los resultados están combinados vía *rbindlist* y se retornan como una tabla simple.

```
data.table(mes.csv=Sys.glob("*.csv")) [, fread(mes.csv) ,
by=mes.csv]
```

Ejercicios

- Usa vuelos`[, fwrite(.SD), by=origen]`para escribir un archivo CSV para cada aeropuerto de Nueva York.

- Crea `CSV.dt`, a data.table de nombres de archivo CSV, usando Sys.glob("*.csv")
- Usa `CSV.dt[, fread(origen.csv), by=origen.csv]` para leerlos de vuelta a R.

Uniendo: cuando i es un data.table

- Piensa en términos básicos de unidades: filas, columnas, grupos.
- La sintaxis de data.table provee un lugar único para cada uno de ellos.

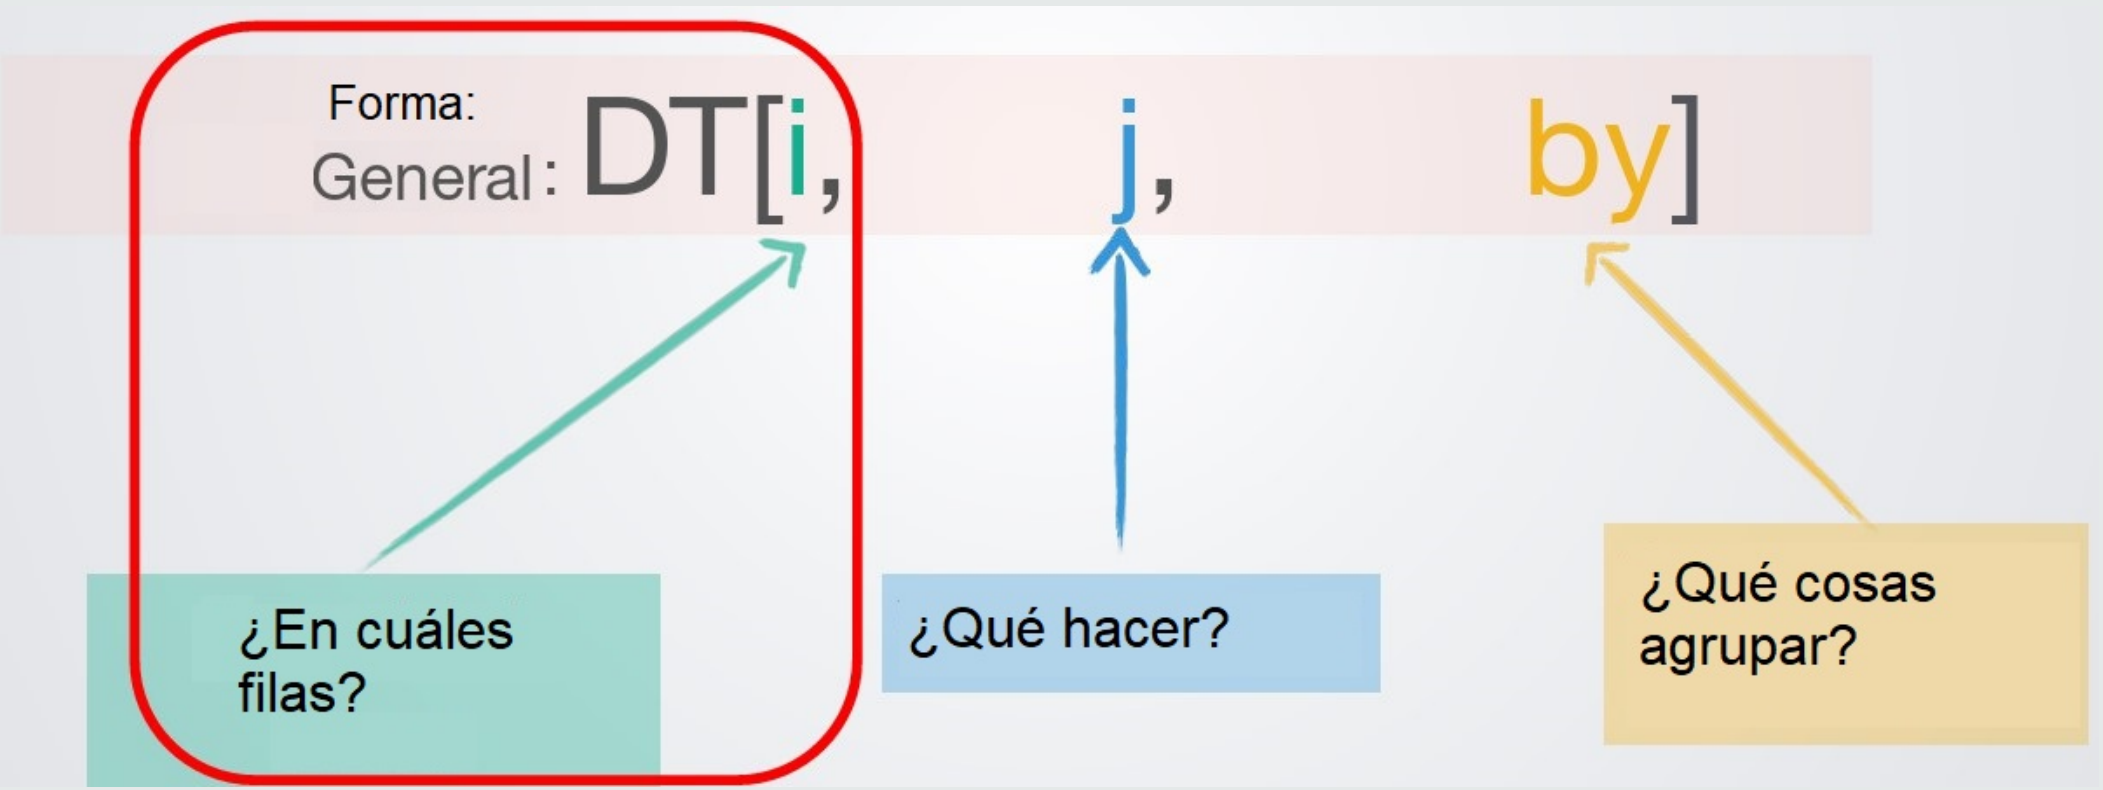

Une DT con la tabla i: DT[i]

- Retorna cada una de las filas en vuelos que coincida con una fila en tres dias,
- con una fila NA al final del día que no coincida.

```
(tres_dias<- rbind(
  data.table(mes=3, dia=17, evento="St.Patrick"),
  data.table(mes=9, dia=26, evento="Cumpleaños"),
  data.table(mes=12, dia=25, evento="Navidad")))
```

```
    mes   dia     evento
  <num> <num>     <char>
1:     3    17 St.Patrick
2:     9    26 Cumpleaños
3:    12    25    Navidad
```

```
vuelos[tres_dias, on=c("mes","dia")]
```

Unir dos tablas, c/múltiples argumentos

- `mult="all"` está por defecto. Es decir, retorna todas las filas que coincidan.
- Al principio o al final hay otras opciones, retorna una fila por vuelo, para cada fila de los tres días.

```
1  vuelos[tres_dias, on=c("mes","dia"), mult="first"]
```

```
    anio   mes   dia horario_salida salida_programada atraso_salida
   <int> <int> <int>          <int>             <int>         <num>
1:  2013     3    17             17              2253            84
2:  2013     9    26            451               500            -9
3:  2013    12    25            456               500            -4
   horario_llegada llegada_programada atraso_llegada aerolinea vuelo
             <int>               <int>          <num>    <char> <int>
1:            134                  14             80        B6   112
2:            619                 648            -29        US  1877
3:            649                 651             -2        US  1895
   codigo_cola origen destino tiempo_vuelo distancia  hora minuto
        <char> <char>  <char>        <num>     <num> <num>  <num>
1:      N583JB    JFK     BUF           56       301    22     53
2:      N155UW    EWR     CLT           72       529     5      0
3:      N156UW    EWR     CLT           98       529     5      0
           fecha_hora nuevita     evento
               <POSc>  <char>     <char>
1: 2013-03-17 22:00:00   HOLA! St.Patrick
2: 2013-09-26 05:00:00   HOLA! Cumpleaños
3: 2013-12-25 05:00:00   HOLA!    Navidad
```

Unir dos tablas, c/múltiples argumentos

viene del slide anterior...

```
1  vuelos[tres_dias, on=c("mes","dia"), mult="last"]
```

```
    anio   mes   dia horario_salida salida_programada atraso_salida
   <int> <int> <int>          <int>             <int>         <num>
1:  2013     3    17             NA               650            NA
2:  2013     9    26             NA              1240            NA
3:  2013    12    25             NA              1930            NA
   horario_llegada llegada_programada atraso_llegada aerolinea vuelo
             <int>              <int>          <num>    <char> <int>
1:              NA                827             NA        UA   883
2:              NA               1525             NA        WN  4720
3:              NA               2115             NA        MQ  3535
   codigo_cola origen destino tiempo_vuelo distancia  hora minuto
        <char> <char>  <char>        <num>     <num> <num>  <num>
1:        <NA>    EWR     ORD           NA       719     6     50
2:      N691WN    EWR     HOU           NA      1411    12     40
3:      N509MQ    JFK     CMH           NA       483    19     30
            fecha_hora nuevita     evento
                <POSc>  <char>     <char>
1: 2013-03-17 06:00:00   HOLA! St.Patrick
2: 2013-09-26 12:00:00   HOLA! Cumpleaños
3: 2013-12-25 19:00:00   HOLA!    Navidad
```

Uniendo dos tablas, sin filas NA

- `nomatch=0L` para retornar a 0 filas cuando no hay coincidencias. (en vez de 1 NA fila)

```
1  vuelos[tres_dias, on=c("mes","dia"), nomatch=0L]
```

```
      anio   mes   dia horario_salida salida_programada atraso_salida
     <int> <int> <int>          <int>              <int>         <num>
  1:  2013     3    17             17               2253            84
  2:  2013     3    17             27               2358            29
  3:  2013     3    17             30               2355            35
  4:  2013     3    17             31               2359            32
  5:  2013     3    17             57               2100           237
 ---
2618:  2013    12    25           2357               2359            -2
2619:  2013    12    25             NA               1630            NA
2620:  2013    12    25             NA               1525            NA
2621:  2013    12    25             NA               1100            NA
2622:  2013    12    25             NA               1930            NA
      horario_llegada llegada_programada atraso_llegada aerolinea vuelo
                <int>               <int>          <num>    <char> <int>
  1:             134                  14             80        B6   112
  2:             355                 338             17        B6   707
  3:             405                 340             25        B6   739
  4:             403                 338             25        B6   727
  5:             321                2327            234        DL  1247
 ---
2618:             433                 437             -4        B6   839
```

Uniendo dos tablas usando setkey

- `setkey(DT, col1, col2)` usa para ordenar DT por col1 y col2
- Las uniones son rápidas, y no necesitan que se especifiquen con `on=`, si los datos ya tienen `key`

```
1  setkey(tres_dias, mes, dia)
```

```
1  setkey(vuelos, mes, dia)
```

```
1  vuelos[tres_dias]
```

```
Key: <mes, dia>
    anio   mes   dia horario_salida salida_programada atraso_salida
   <int> <int> <int>          <int>             <int>         <num>
1:  2013     3    17             17              2253            84
2:  2013     3    17             27              2358            29
3:  2013     3    17             30              2355            35
   horario_llegada llegada_programada atraso_llegada aerolinea vuelo
             <int>               <int>          <num>    <char> <int>
1:             134                  14             80        B6   112
2:             355                 338             17        B6   707
3:             405                 340             25        B6   739
   codigo_cola origen destino tiempo_vuelo distancia  hora minuto
        <char> <char>  <char>        <num>     <num> <num>  <num>
1:      N583JB    JFK     BUF           56       301    22     53
2:      N529JB    JFK     SJU          188      1598    23     58
3:      N592JB    JFK     PSE          195      1617    23     55
```

Uniendo dos tablas de otra forma

- Uniendo de otra manera siempre devuelve al menos una fila por cada vuelo, NA si no coincide.
- Recuerda:`DT[i]` significa que retorna una fila por cada elemento en i.

```
1   (join.dt <- tres_dias[vuelos, on=c("mes","dia")][order(is.na(evento))])
```

```
    mes   dia     evento  anio horario_salida salida_programada atraso_salida
  <int> <int>     <char> <int>          <int>             <int>         <num>
1:     3    17 St.Patrick  2013             17              2253            84
2:     3    17 St.Patrick  2013             27              2358            29
3:     3    17 St.Patrick  2013             30              2355            35
   horario_llegada llegada_programada atraso_llegada aerolinea vuelo
             <int>               <int>          <num>    <char> <int>
1:             134                  14             80        B6   112
2:             355                 338             17        B6   707
3:             405                 340             25        B6   739
   codigo_cola origen destino tiempo_vuelo distancia  hora minuto
        <char> <char>  <char>        <num>     <num> <num>  <num>
1:      N583JB    JFK     BUF           56       301    22     53
2:      N529JB    JFK     SJU          188      1598    23     58
3:      N592JB    JFK     PSE          195      1617    23     55
            fecha_hora nuevita
                <POSc>  <char>
1: 2013-03-17 22:00:00   HOLA!
2: 2013-03-17 23:00:00   HOLA!
3: 2013-03-17 23:00:00   HOLA!
```

Ejercicios

- **Crea una tabla de datos de aeropuertos de la siguiente forma:**

	codigo	nombre
1	JFK	kennedy
2	LGA	Laguardia
3	EWR	Newark

- Une usando vuelos[airports, `on=.(origen=codigo)]` que significa unir para unirse a la columna de origen en vuelos con el código columnas en aeropuertos.

histograma de las distancias

- o *mean* por cada distancia (0,1000, 2000, etc)

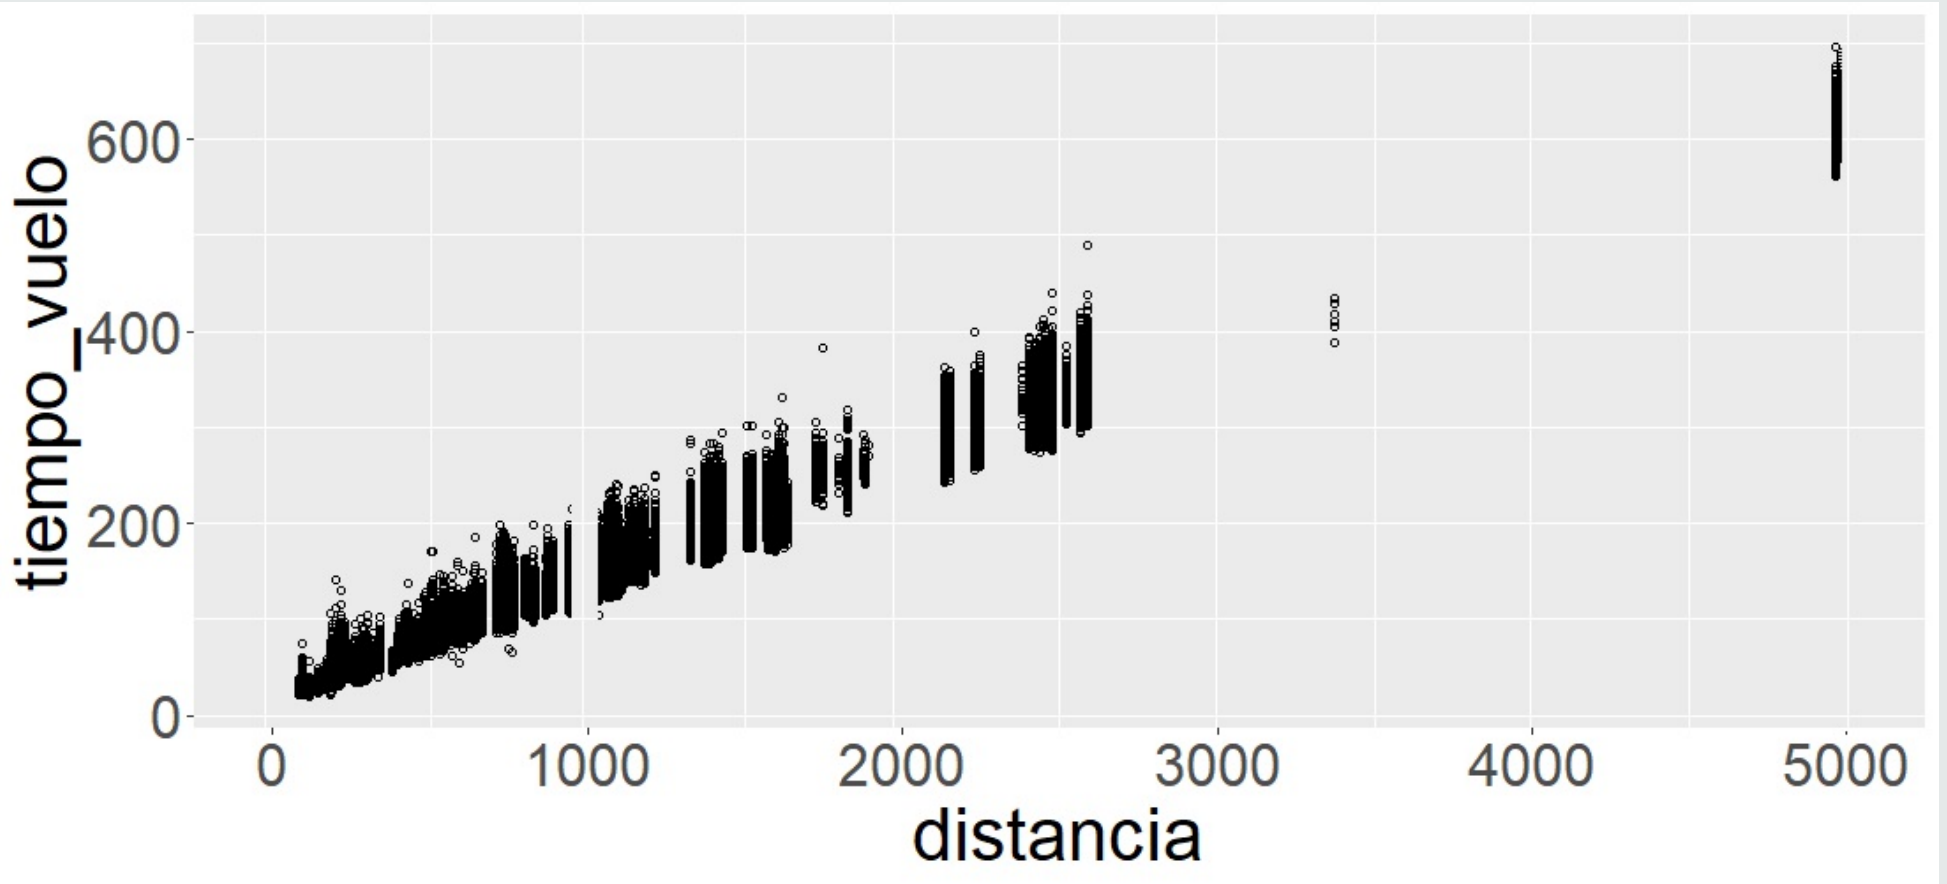

Define los contenedores del histograma

```
grid.point <- seq(0, 5000, by=1000)
grid.dt <- data.table(grid.point, distancia=grid.point)
```

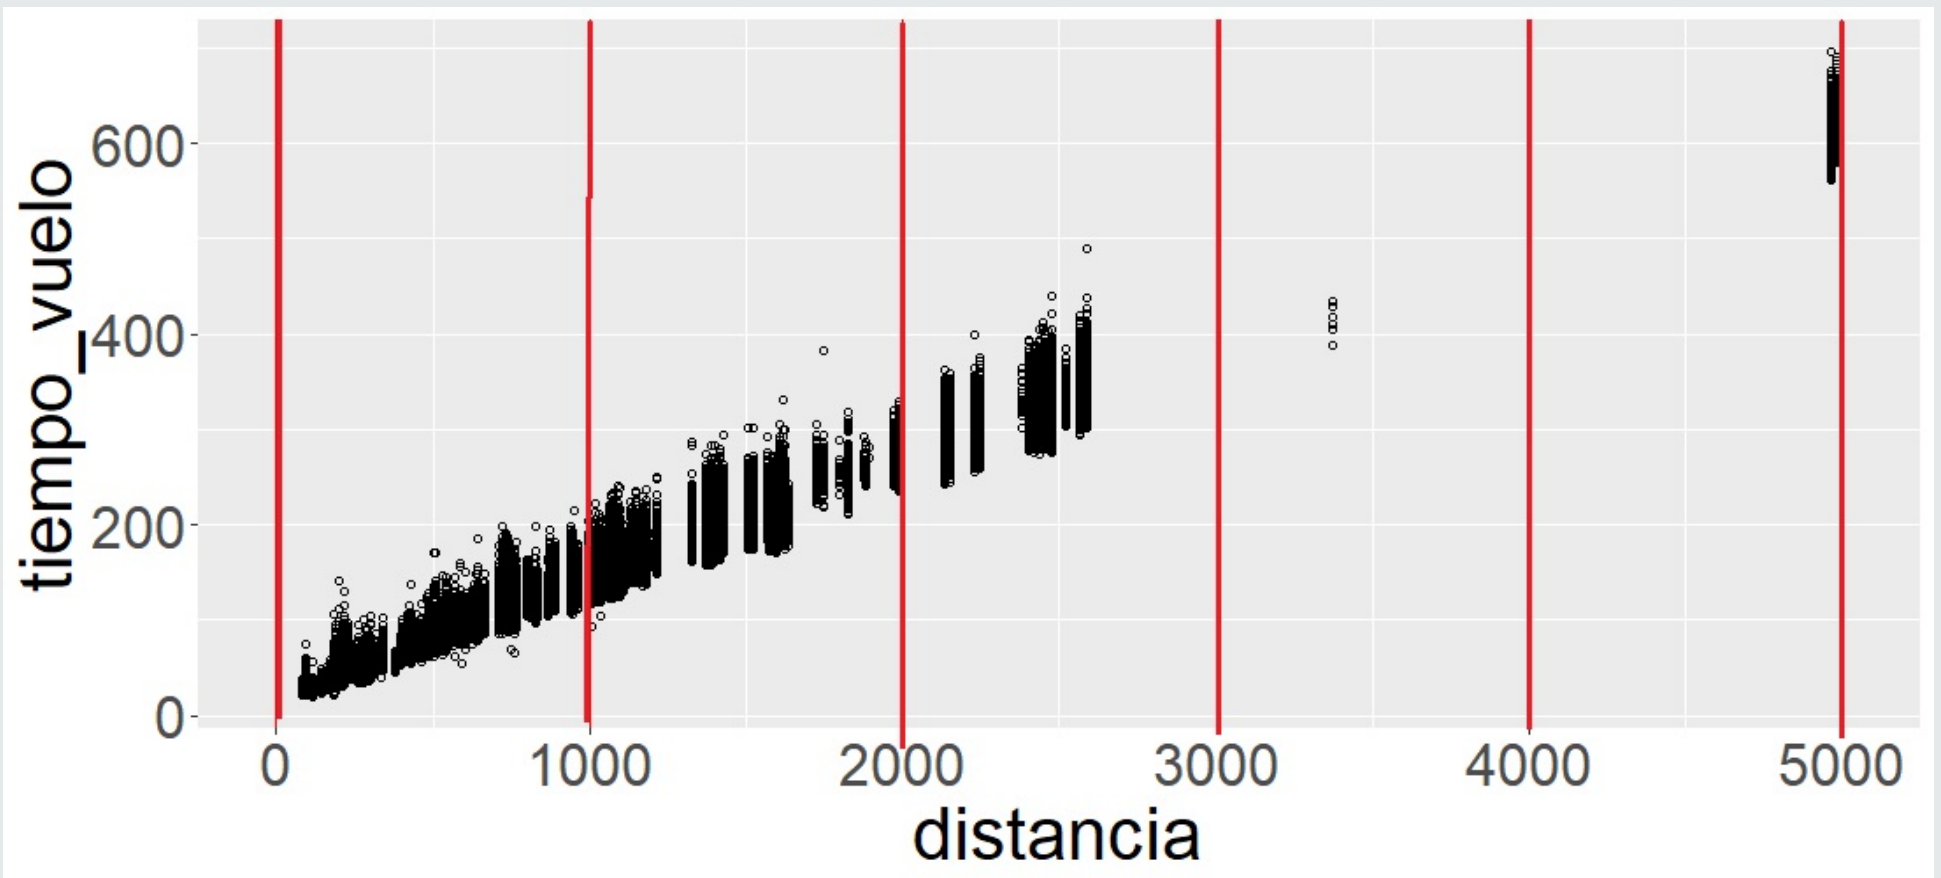

Rolling join, roll=Inf

- Cada punto de la cuadrícula coincide con los vuelos que ocurren después.

```
1  setkey(grid.dt, distancia)
2  setkey(vuelos, distancia)
3  (join.dt <- grid.dt[vuelos, roll=Inf])
```

```
Key: <distancia>
   grid.point distancia
        <num>     <num>
1:          0         0
2:       1000      1000
3:       2000      2000
```

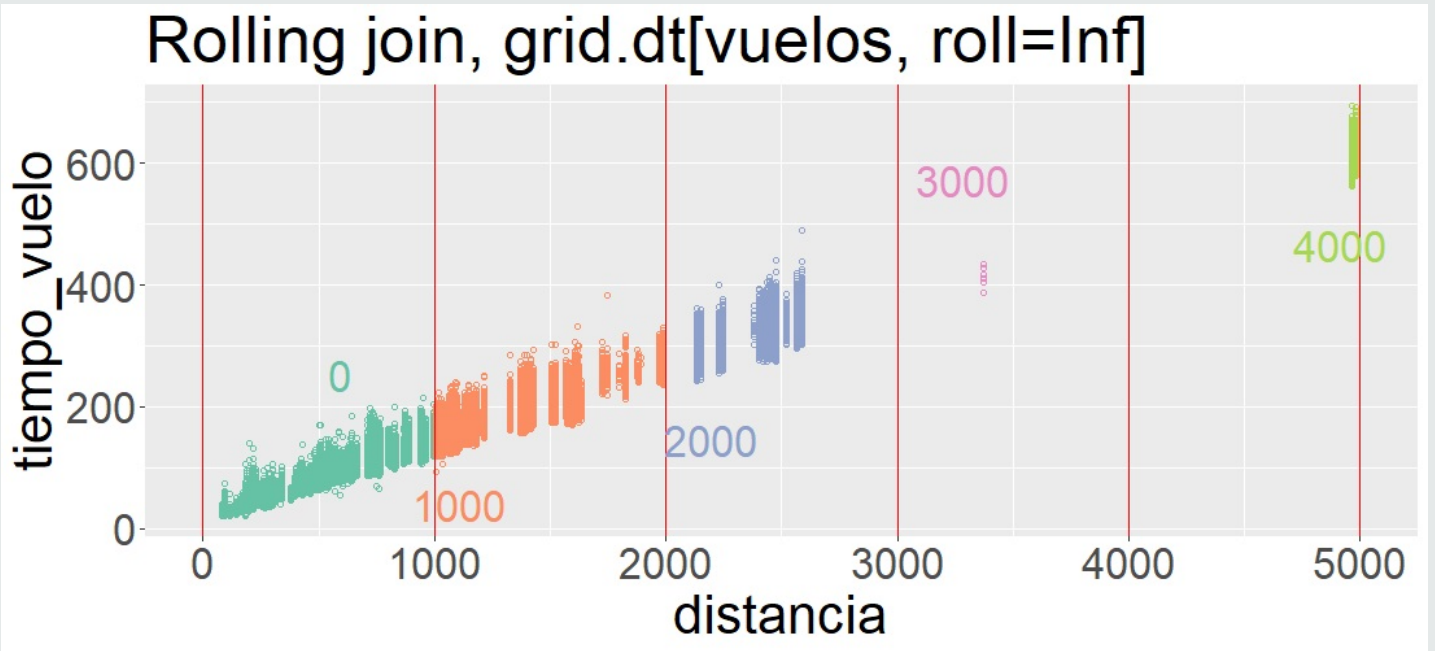

Rolling join, roll=-Inf

- Cada punto de la cuadrícula coincide con los vuelos que ocurren antes.

```
  1   setkey(grid.dt, distancia)
  2   setkey(vuelos, distancia)
  3   (join.dt <- grid.dt[vuelos, roll=-Inf])
```

```
Key: <distancia>
   grid.point distancia
        <num>     <num>
1:          0         0
2:       1000      1000
3:       2000      2000
```

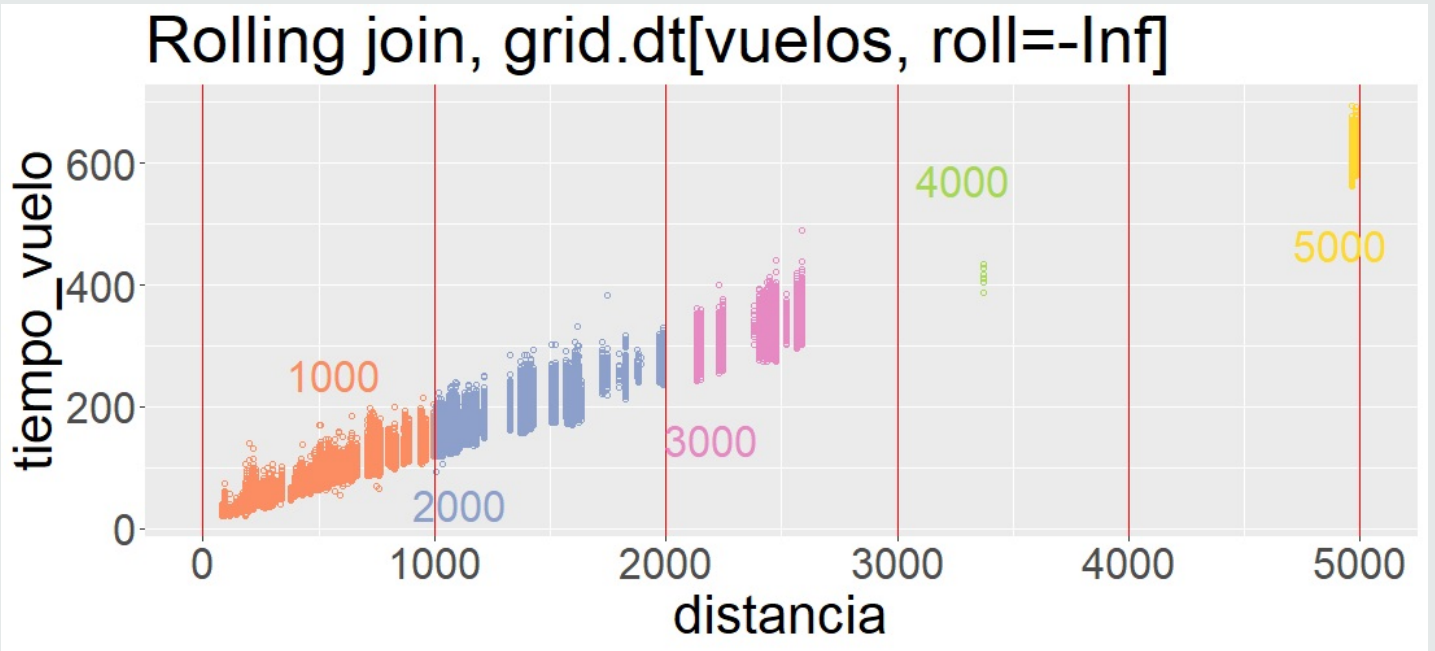

Rolling join, roll="nearest"

- Cada punto de la cuadrícula coincide con los vuelos que ocurren más cerca.

```
1  setkey(grid.dt, distancia)
2  setkey(vuelos, distancia)
3  (join.dt <- grid.dt[vuelos, roll="nearest"])
```

```
Key: <distancia>
   grid.point distancia
        <num>     <num>
1:          0         0
2:       1000      1000
3:       2000      2000
```

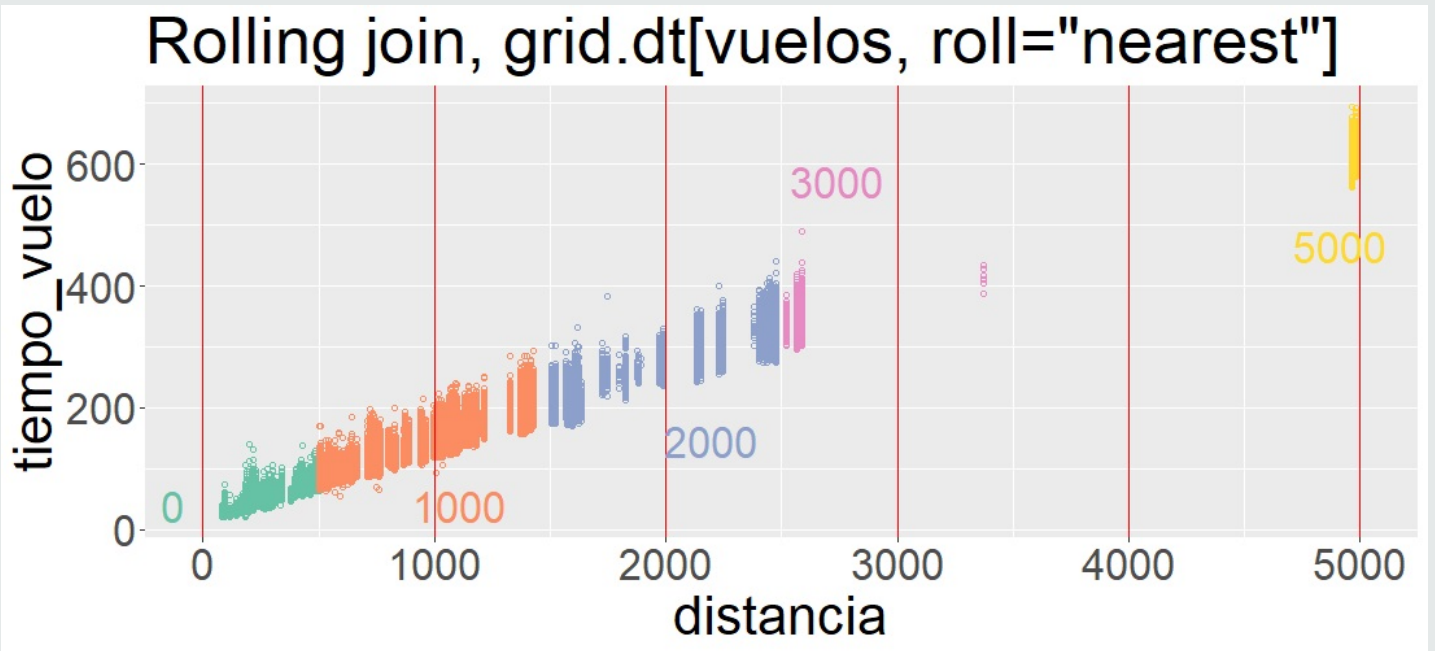

Resumiendo después de: rolling join

- ¿ Cómo computar un resumen/histograma?

```
1  join.dt[, .(num_vuelos=.N, mean_minutes=mean(tiempo_vuelo)), by=grid.point]
```

```
   grid.point num_vuelos mean_minutes
        <num>      <int>         <num>
1:          0      80327            NA
2:       1000     183736            NA
```

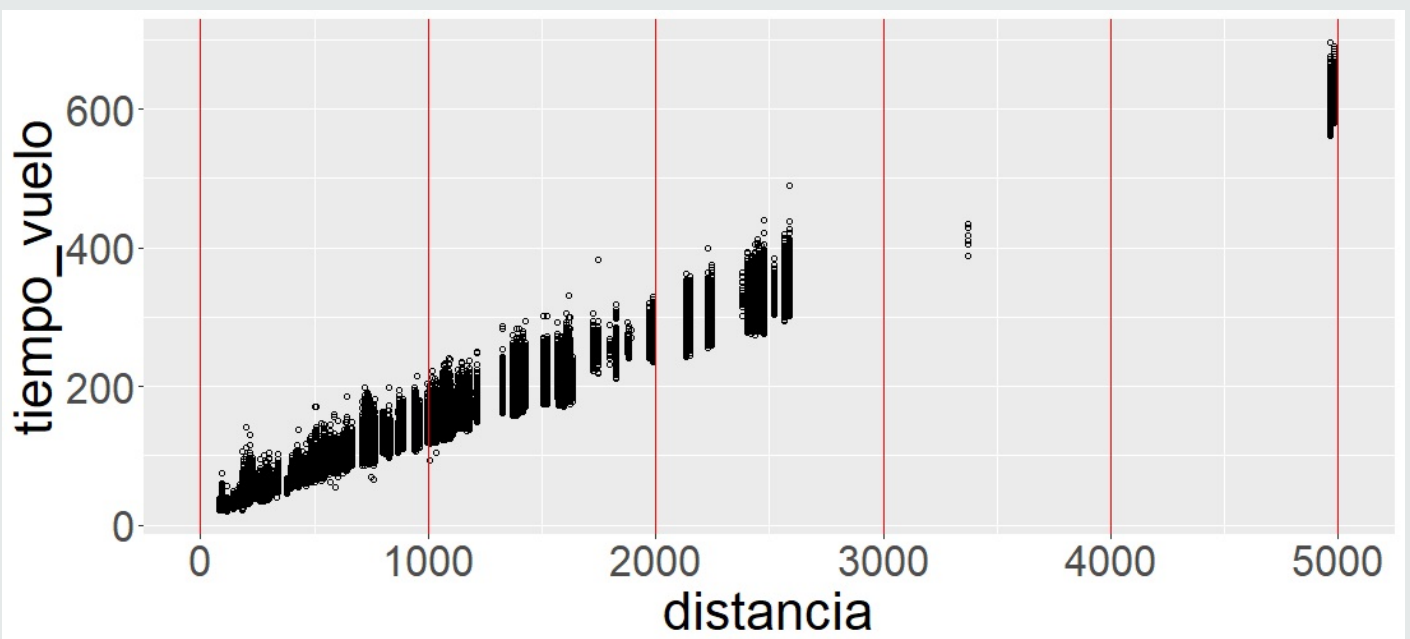

Desigualdades une con on=. (DTcol < icol)

Une todas las filas que satisfacen las desigualdades dadas.

```
1   (rect.dt <- data.table(   grid.point, min_dist=grid.point-200, max_dist=grid.point+400))
```

```
   grid.point min_dist max_dist
        <num>    <num>    <num>
1:          0     -200      400
2:       1000      800     1400
```

```
1   head(join.dt <- rect.dt[vuelos, .( distancia, tiempo_vuelo, grid.point), on=.( min_dist<distancia, max_dist>
```

```
   distancia tiempo_vuelo grid.point
       <num>        <num>      <num>
1:        17           NA          0
2:        80           30          0
```

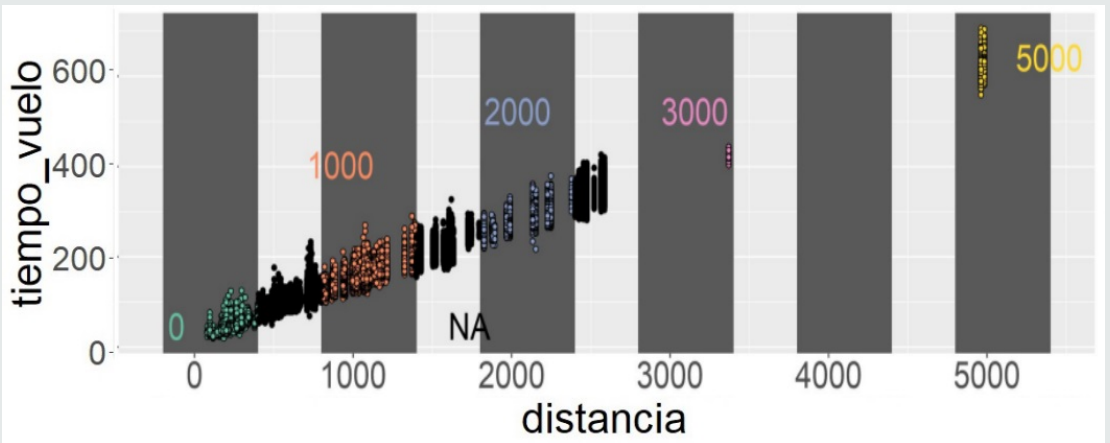

Computa por cada fila en la tabla i

- Piensa en términos básicos de unidades: filas, columnas, grupos,
- La sintaxis de data.table provee un lugar único para cada uno de ellos.

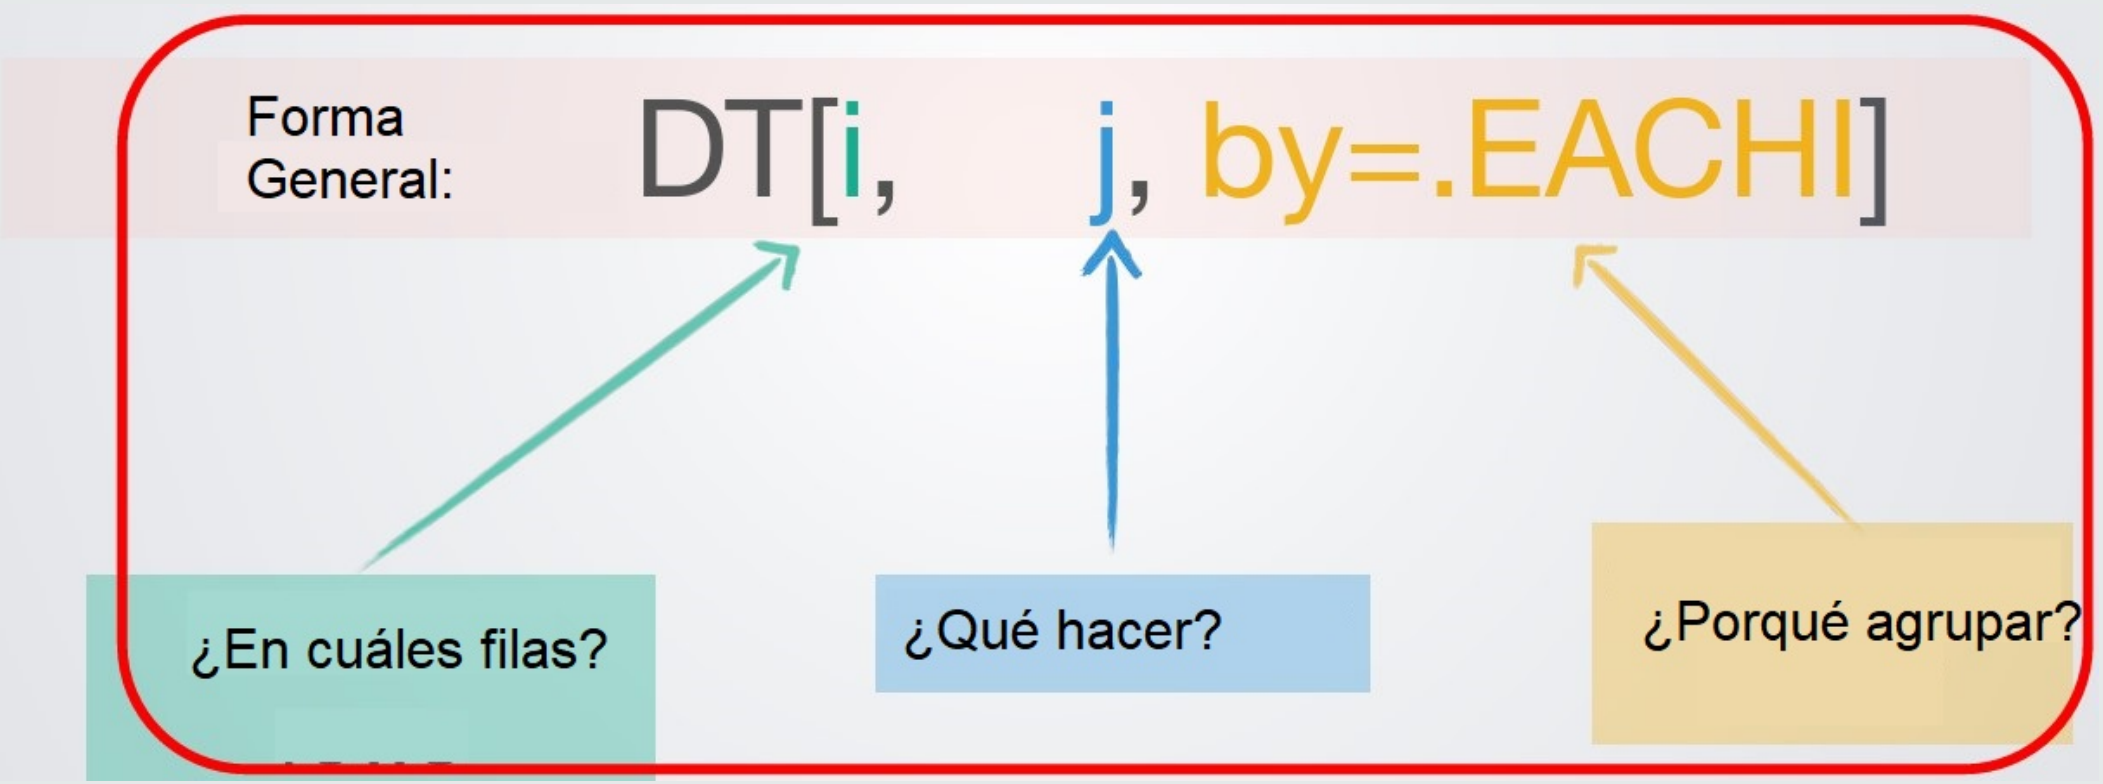

Resumir uniendo via by=.EACHI

```
vuelos[tres_dias, .(
  mean_aire_time=mean(tiempo_vuelo),
  num_vuelos=.N
  ), by=.EACHI, on=.(mes,dia)]
```

```
Key: <mes, dia>
     mes   dia mean_aire_time num_vuelos
   <int> <int>          <num>      <int>
1:     3    17             NA        907
2:     9    26             NA        996
3:    12    25             NA        719
```

- `DT[ i, j, by=.EACHI, on]` significa que por cada fila en i, miramos las filas en DT la cual coinciden usando en columnas, y computar/retornando j.
- No es lo mismo que `by=`(mes,día) la cual hace el cómputo por cada combinación única de mes y día (mucho menos eficiente si solo quisiéramos el resultado para unas pocas combinaciones)

Remodelación de datos: ancho a largo (melt)

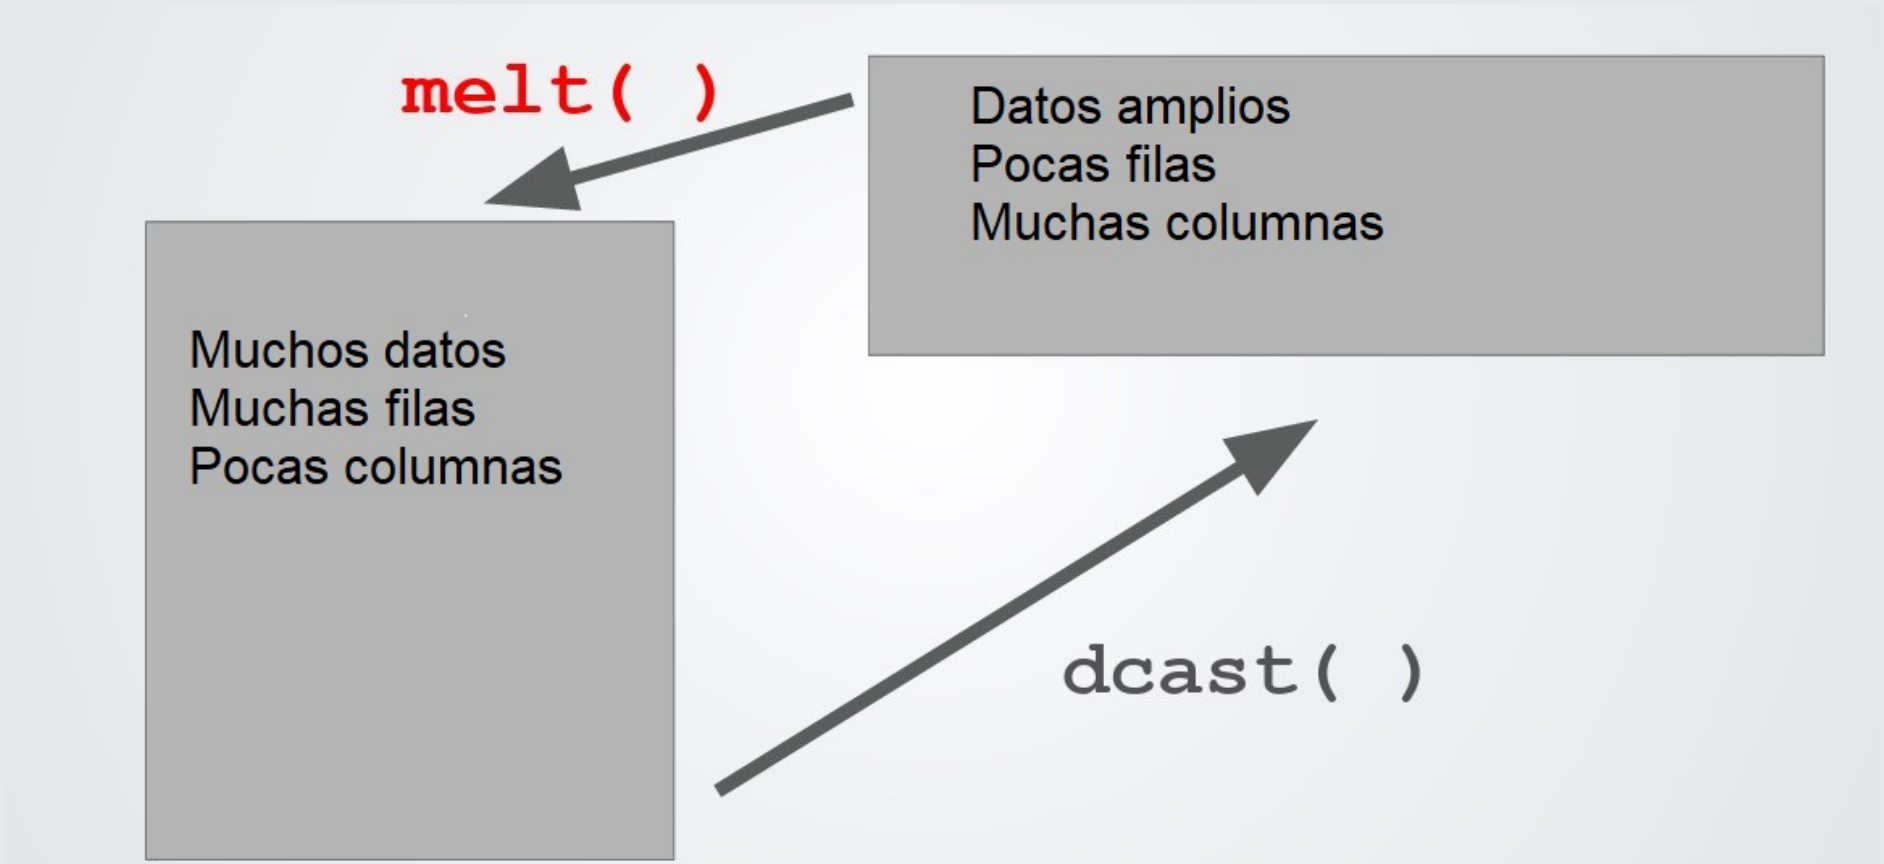

Similar a stats::reshape(dirección="long"), tidyr::pivot_longer()

melt: remodelo de datos de ancho a largo

- ¿ Cómo hacer el gráfico de abajo con datos de flores?
- La tabla de datos flores tiene columnas Largo.Sepalo, Ancho.Sepalo, Largo.Petalo, Ancho.Petalo, Especie.
- Necesitaríamos `facet_grid(part ~ dim) + geom_histogram(aes(cm, fill=Especie))`,
- Donde la columna dim tiene valores Largo o Ancho, parte de los valores son Petalo o Sepalo

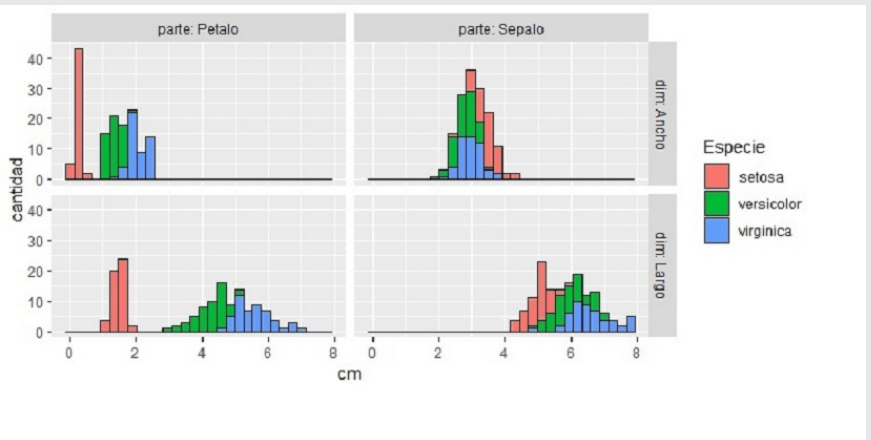

melt:remodelo de ancho a largo de los datos

melt(DT, id.vars=c("Especie","flores"))

Tipo de columna leyenda: Nombre = medida/valor, Nombre = variable,Nombre = id.

	Largo.Sepalo	Ancho.Sepalo	Largo.Petalo	Ancho.Petalo	Especie	flores
1:	5.1	3.5	1.4	0.2	setosa	1
2:	7.0	3.2	4.7	1.4	versicolor	51

Entrada amplia con 4 medidas de columnas

Salida larga con 1 valor de columna

Convierte 4 medidas de entradas en 1 valor de columna y 1 columna de variable como salida.

	valor	Especie	flores	variable
1:	5.1	setosa	1	Largo.Sepalo
2:	3.5	setosa	1	Ancho.Sepalo
3:	1.4	setosa	1	Largo.Petalo
4:	0.2	setosa	1	Ancho.Petalo
5:	7.0	versicolor	51	Largo.Sepalo
6:	3.2	versicolor	51	Ancho.Sepalo
7:	4.7	versicolor	51	Largo.Petalo
8:	1.4	versicolor	51	Ancho.Petalo

melt:remodelo de ancho a largo de los datos

melt(DT,measure.vars=c(“Largo.Sepalo”,“Ancho.Sepalo”,“Largo.Petalo”,“Ancho.Petalo”))

Tipo de columna leyenda: Nombre = medida/valor, Nombre = variable, Nombre = id.

	Largo.Sepalo	Ancho.Sepalo	Largo.Petalo	Ancho.Petalo	Especie	flores
1:	5.1	3.5	1.4	0.2	setosa	1
2:	7.0	3.2	4.7	1.4	versicolor	51

Entrada amplia con 4 medidas de columnas

Salida larga con 1 valor de columna

Convierte 4 medidas de entradas en 1 valor de columna y 1 columna de variable como salida.

	valor	Especie	flores	variable
1:	5.1	setosa	1	Largo.Sepalo
2:	3.5	setosa	1	Ancho.Sepalo
3:	1.4	setosa	1	Largo.Petalo
4:	0.2	setosa	1	Ancho.Petalo
5:	7.0	versicolor	51	Largo.Sepalo
6:	3.2	versicolor	51	Ancho.Sepalo
7:	4.7	versicolor	51	Largo.Petalo
8:	1.4	versicolor	51	Ancho.Petalo

melt:remodelo de ancho a largo de los datos

```
melt(DT, measure.vars=patterns(".*[.].*"))
```

Tipo de columna leyenda: `Nombre` = medida/valor, `Nombre` = variable, Nombre = id.

	Largo.Sepalo	Ancho.Sepalo	Largo.Petalo	Ancho.Petalo	Especie	flores
1:	5.1	3.5	1.4	0.2	setosa	1
2:	7.0	3.2	4.7	1.4	versicolor	51

Entrada amplia con 4 medidas de columnas

Salida larga con 1 valor de columna

Convierte 4 medidas de entradas en 1 valor de columna y 1 columna de variable como salida.

	valor	Especie	flores	variable
1:	5.1	setosa	1	Largo.Sepalo
2:	3.5	setosa	1	Ancho.Sepalo
3:	1.4	setosa	1	Largo.Petalo
4:	0.2	setosa	1	Ancho.Petalo
5:	7.0	versicolor	51	Largo.Sepalo
6:	3.2	versicolor	51	Ancho.Sepalo
7:	4.7	versicolor	51	Largo.Petalo
8:	1.4	versicolor	51	Ancho.Petalo

melt:remodelado ancho a largo de los datos

```
melt(DT, id.vars=c("ID1","ID2"))
melt(DT, measure.vars=c("valueA","valueB"))
melt(DT, measure.vars=patterns("regular expression"))
```

- Ejercicio: `melt` las columnas atraso_llegada y atraso_salida de los datos de vuelos,especificando las medidas como `measure.vars`
- Adicionalmente especifica `id.vars` que limita con las columnas y hace copia de la salida (*output)*.

melt: measure() nuevo GitHub

`melt(DT,measure.vars=measure(part,dim,pattern="(.*)[.](.*)"))` Captura groups()en patrones usando para definir las columnas variables de salidas.

Tipo de leyenda columna: Nombre = medida/valor, `Nombre` = variable, `Nombre` = id.

	Largo.Sepalo	Ancho.Sepalo	Largo.Petalo	Ancho.Petalo	Especie	flores
1:	5.1	3.5	1.4	0.2	setosa	1
2:	7.0	3.2	4.7	1.4	versicolor	51

Entrada amplia con 4 medidas de columnas

Salida Larga con 1 valor de columna

Convierte 4 medidas de entradas de columnas en 1 valor de columna

	valor	Especie	flores	part	dim
1:	5.1	setosa	1	Sepalo	Largo
2:	3.5	setosa	1	Sepalo	Ancho
3:	1.4	setosa	1	Petalo	Largo
4:	0.2	setosa	1	Petalo	Ancho
5:	7.0	versicolor	51	Sepalo	Largo
6:	3.2	versicolor	51	Sepalo	Ancho
7:	4.7	versicolor	51	Petalo	Largo
8:	1.4	versicolor	51	Petalo	Ancho

y 2 columnas de variable salida

melt: measure()nuevo GitHub

`melt(DT,measure.vars=measure(part,dim,sep="."))` Usa columnas de entrada en la mayoría de los grupos después de dividir (aqui son 2)

Tipo de leyenda columna: Nombre = medida/valor, `Nombre` = variable, `Nombre` = id.

	Largo.Sepalo	Ancho.Sepalo	Largo.Petalo	Ancho.Petalo	Especie	flores
1:	5.1	3.5	1.4	0.2	setosa	1
2:	7.0	3.2	4.7	1.4	versicolor	51

Entrada amplia con 4 medidas de columnas

Salida Larga con 1 valor de columna

Convierte 4 medidas de entradas de columnas en 1 valor de columna

	valor	Especie	flores	part	dim
1:	5.1	setosa	1	Sepalo	Largo
2:	3.5	setosa	1	Sepalo	Ancho
3:	1.4	setosa	1	Petalo	Largo
4:	0.2	setosa	1	Petalo	Ancho
5:	7.0	versicolor	51	Sepalo	Largo
6:	3.2	versicolor	51	Sepalo	Ancho
7:	4.7	versicolor	51	Petalo	Largo
8:	1.4	versicolor	51	Petalo	Ancho

y 2 columnas de variable salida

melt con measure(),nuevo en GitHub

- Ejercicio: hace un gráfico con los datos de flores.
- Primero convierte flores en un data.table, luego reacomoda la forma usando `melt(DT, measure=measure(----------), value.name="cm")`
- library(ggplot2); ggplot() + facet_grid(part ~ dim) + geom_histogram(aes(cm, fill=Especie), data=output_of_melt)

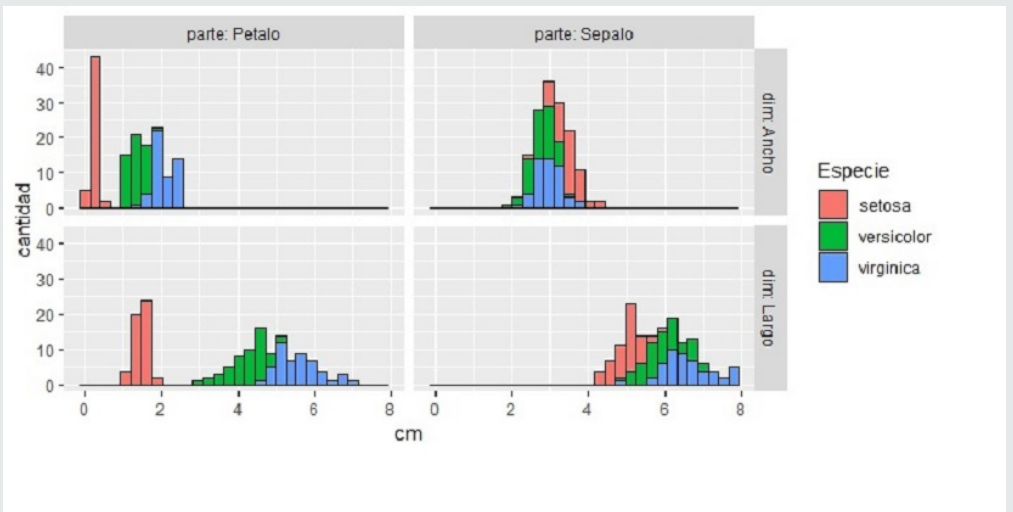

melt con measure(), nuevo en GitHub

```
melt(DT, measure.vars=measure(part, value.name, sep="."))
```

Tipo de columna leyenda: Nombre= medida/valor, Nombre=variable, Nombre= id.

	Largo.Sepalo	Ancho.Sepalo	Largo.Petalo	Ancho.Petalo	Especie	flores
1:	5.1	3.5	1.4	0.2	setosa	1
2:	7.0	3.2	4.7	1.4	versicolor	51

Entrada amplia con 4 medidas de columnas

Salida Larga con 1 valor de columna

	Largo	Ancho	Especie	flores	part
1:	5.1	3.5	setosa	1	Sepalo
2:	1.4	0.2	setosa	1	Petalo
3:	7.0	3.2	versicolor	51	Sepalo
4:	4.7	1.4	versicolor	51	Petalo

Columna de valor de salida por cada dimensión, y por parte de variable columna

melt con measure(), nuevo en GitHub

```
melt(DT, measure.vars=measure(value.name, dim, sep="."))
```

Tipo de columna leyenda: Nombre = medida/valor, Nombre = variable, Nombre = id.

	Largo.Sepalo	Ancho.Sepalo	Largo.Petalo	Ancho.Petalo	Especie	flores
1:	5.1	3.5	1.4	0.2	setosa	1
2:	7.0	3.2	4.7	1.4	versicolor	51

Entrada amplia com 4 medidas de columnas

Salida larga con 1 valor de columna

	Sepalo	Petalo	Especie	flores	dim
1:	5.1	1.4	setosa	1	Largo
2:	3.5	0.2	setosa	1	Ancho
3:	7.0	4.7	versicolor	51	Largo
4:	3.2	1.4	versicolor	51	Ancho

Columna valor de salida por cada parte, y columna variable por dim

melt con measure(), nueva en GitHub

- Ejercicio: para mostrar que Sepalo es más larga que Petalo, hace un gráfico con los datos flores. Primero convertí flores en data.table.
- Luego usa melt con measure() para reajustar.
- library(ggplot2); ggplot() + facet_grid(.~dim) + geom_point(aes(Petalo, Sepalo, color=Especie), data=output_of_melt)+ geom_abline(slope=1, intercept=0)

ejemplos de fusión adaptados de: Hocking TD. Datos de ancho a alto remodelar usando expresiones regulares y el nc paquete. (2021), doi:10.32614/RJ-2021-029

melt ejercicios para los datos de vuelos

- Ejercicio: hace un gráfico abajo con los datos de vuelos.
- Usa melt con ambos patterns() o measure() para readaptar la forma.
- ggplot() + geom_histogram(aes(demora_minutos, fill=variable), data=output_of_melt)

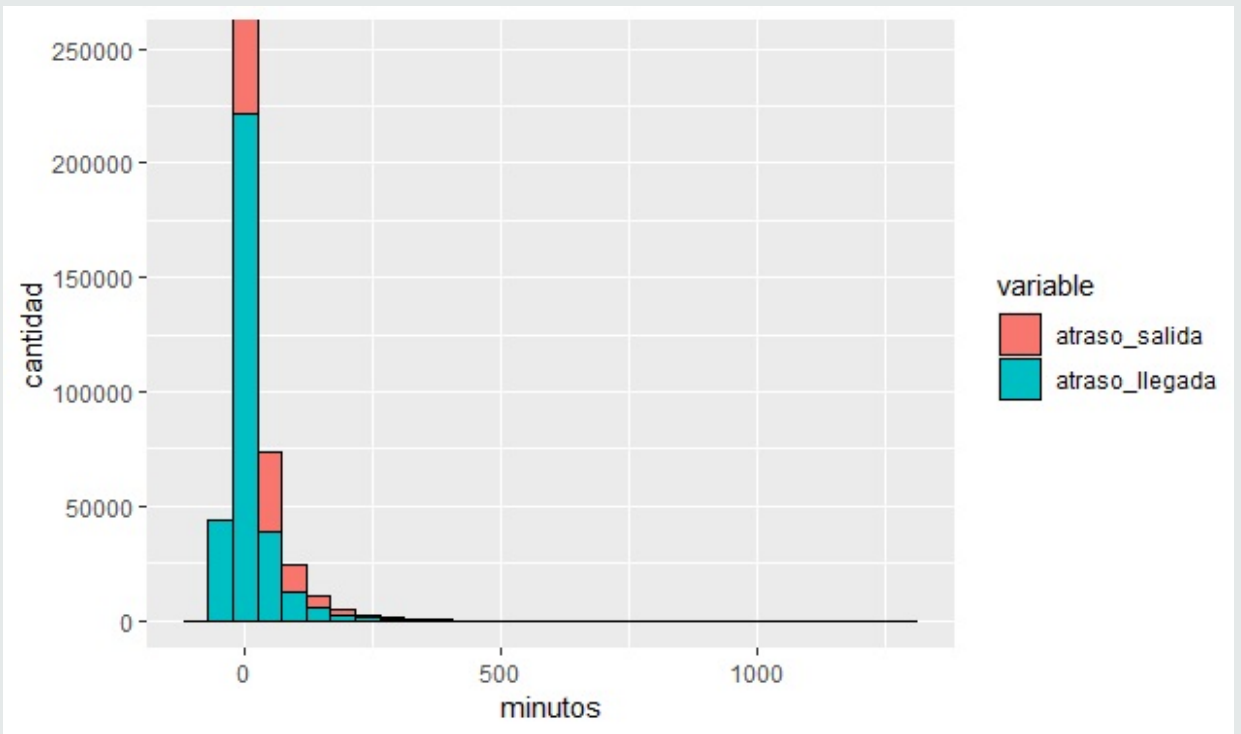

Reajustando datos: larga forma (dcast)

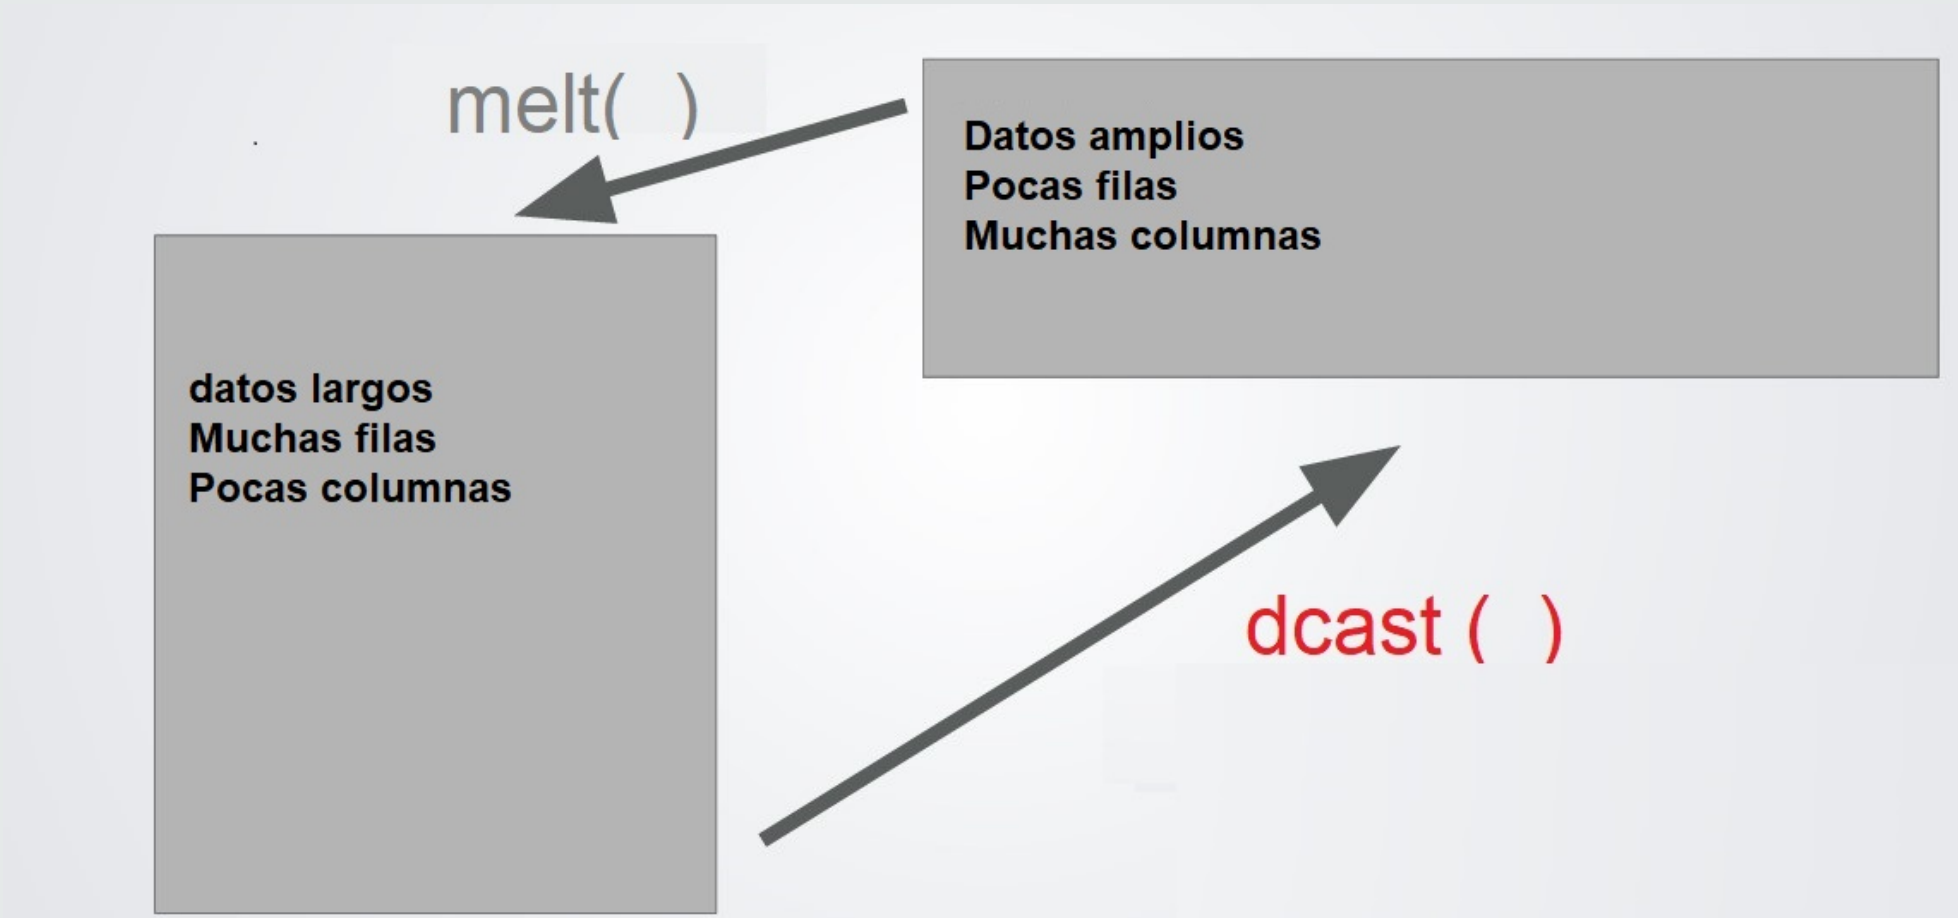

similar a stats::reshape(direction="wide"), tidyr::pivot_wider()

dcast:ajuste de largas formas

- dcast puede obtener la versión original del datos de flores volviendo de la versión grande.

```
flores.dt=data.table(flores)[, flores := .I] # es decir número de fila en data.table
```

```
flores.largo=melt(flores.dt,measure=measure(part,dim,sep="."))
head(flores.largo)
```

```
   Especie flores   part    dim value
    <fctr>  <int> <char> <char> <num>
1:  setosa      1  Largo Sepalo   5.1
2:  setosa      2  Largo Sepalo   4.9
3:  setosa      3  Largo Sepalo   4.7
4:  setosa      4  Largo Sepalo   4.6
5:  setosa      5  Largo Sepalo   5.0
6:  setosa      6  Largo Sepalo   5.4
```

```
# La formula indica donde esta puesto los diferentes valores de la variable: rows #~ cols

flores.ancho=dcast(flores.largo, flores ~ part + dim, sep=".")
head(flores.ancho)
```

```
Key: <flores>
   flores Ancho.Petalo Ancho.Sepalo Largo.Petalo Largo.Sepalo
    <int>        <num>        <num>        <num>        <num>
1:      1          0.2          3.5          1.4          5.1
2:      2          0.2          3.0          1.4          4.9
3:      3          0.2          3.2          1.3          4.7
4:      4          0.2          3.1          1.5          4.6
5:      5          0.2          3.6          1.4          5.0
6:      6          0.4          3.9          1.7          5.4
```

dcast:ajuste de largas formas

- dcast puede computarse a resumenes/funciones agregadas

```
1  flores.largo=melt(flores.dt,measure=measure(part,dim,sep="."),value.name="cm")
2  flores.largo
```

```
      Especie flores   part    dim    cm
       <fctr>  <int> <char> <char> <num>
  1:    setosa      1  Largo Sepalo   5.1
  2:    setosa      2  Largo Sepalo   4.9
  3:    setosa      3  Largo Sepalo   4.7
  4:    setosa      4  Largo Sepalo   4.6
  5:    setosa      5  Largo Sepalo   5.0
 ---
596: virginica    146  Ancho Petalo   2.3
597: virginica    147  Ancho Petalo   1.9
598: virginica    148  Ancho Petalo   2.0
599: virginica    149  Ancho Petalo   2.3
600: virginica    150  Ancho Petalo   1.8
```

```
1  dcast(flores.largo, Especie ~ dim, fun.aggregate=mean, value.var="cm")
```

```
Key: <Especie>
      Especie Petalo Sepalo
       <fctr>  <num>  <num>
1:     setosa  0.854  4.217
2: versicolor  2.793  4.353
3:  virginica  3.789  4.781
```

dcast:ajustes de largas formas

- dcast puede computar muchos resumenes/funciones agregadas

```
flores.largo=melt(flores.dt,measure=measure(part,dim,sep="."),value.name="cm")
flores.largo
```

```
      Especie flores   part    dim    cm
       <fctr>  <int> <char> <char> <num>
  1:    setosa      1  Largo Sepalo   5.1
  2:    setosa      2  Largo Sepalo   4.9
  3:    setosa      3  Largo Sepalo   4.7
  4:    setosa      4  Largo Sepalo   4.6
  5:    setosa      5  Largo Sepalo   5.0
 ---
596: virginica    146  Ancho Petalo   2.3
597: virginica    147  Ancho Petalo   1.9
598: virginica    148  Ancho Petalo   2.0
599: virginica    149  Ancho Petalo   2.3
600: virginica    150  Ancho Petalo   1.8
```

```
dcast(flores.largo, Especie ~ dim, fun.aggregate=list(min, mean, max)) #value.var="cm")
```

```
Key: <Especie>
      Especie cm_min_Petalo cm_min_Sepalo cm_mean_Petalo cm_mean_Sepalo
       <fctr>         <num>         <num>          <num>          <num>
1:     setosa           0.1           2.3          0.854          4.217
2: versicolor           1.0           2.0          2.793          4.353
3:  virginica           1.4           2.2          3.789          4.781
   cm_max_Petalo cm_max_Sepalo
           <num>         <num>
```

dcast: reajuste de largas formas

- dcast puede computar muchos valores de columnas.

```
1  flores.largo=melt(flores.dt,measure=measure(part,value.name,sep="."))
2  flores.largo
```

```
      Especie flores   part Sepalo Petalo
       <fctr>  <int> <char>  <num>  <num>
  1:    setosa      1  Largo    5.1    1.4
  2:    setosa      2  Largo    4.9    1.4
  3:    setosa      3  Largo    4.7    1.3
  4:    setosa      4  Largo    4.6    1.5
  5:    setosa      5  Largo    5.0    1.4
 ---
296: virginica    146  Ancho    3.0    2.3
297: virginica    147  Ancho    2.5    1.9
298: virginica    148  Ancho    3.0    2.0
299: virginica    149  Ancho    3.4    2.3
300: virginica    150  Ancho    3.0    1.8
```

```
1  dcast(flores.largo, Especie + part ~ ., fun.aggregate=list(min, max), value.var=c("Sepalo", "Petalo"))
```

```
Key: <Especie, part>
     Especie   part Sepalo_min Petalo_min Sepalo_max Petalo_max
      <fctr> <char>      <num>      <num>      <num>      <num>
1:    setosa  Ancho        2.3        0.1        4.4        0.6
2:    setosa  Largo        4.3        1.0        5.8        1.9
3: versicolor  Ancho        2.0        1.0        3.4        1.8
4: versicolor  Largo        4.9        3.0        7.0        5.1
```

Ejercicios

	destino	EWR	JFK	LGA
1	ABQ	0	278	0
2	ACK	0	277	0
3	AGS	0	0	0
4	ALB	169	0	0
5	ANC	13	0	0

- Hace una table como la de arriba, con una columna por cada origen, y una fila por cada destino(cuanta las entradas de los vuelos). Ayuda: usa destino~origen para crear un destino diferente en cada fila, y un diferente origen en cada columna
- Especifica value.var=c(“atraso_salida”,“atraso_llegada”) con fun.aggregate=mean para comparar el promedio de retrados. Usa esta información para elegir el mejor aeropuerto por cada destino.

Importa data.table en tu paquete

- data.table actualmente es importada para 1400+ paquetes en CRAN.
  -“Imports:data.table” en la descripción.
- “import(data.table)” en NAMESPACE.
- .<- j_variable <- NULL en la primer linea en la función de R para abordarCRAN. NOTA acerca de una función/variable no visible.
- data.table::setDTthreads(2) en ejemplos/testeos para abordar CRAN NOTA: poco tiempo necesita (por defecto data.table usa 1/2 de todo el CPUs)

NOTA 1 CRAN

-`<-variable<-NULL` en la primer linea de la función de R para abordar CRAN NOTA: acerca de funciones/variable no visible.

```
1  mi_funcion <- function(DT) DT[, .(m=mean(x)) , by=y]
```

** Chequea el código de R por posibles problemas... algunas notas para que consideres:

mi_funcion: si no está visible como función global por `.`
mi_funcion: si no está visible como función global variable`x`
mi_funcion: si no está visible como función global variable `y`

- Chequea la nota como arriba, usa el código R de aquí abajo:

```
1  mi_funcion <- function(DT){
2    x <- y <- . <- NULL
3    DT[, .(m=mean(x)), by=y]
4   }
```

NOTA2: CRAN

- CRAN requiere de paquetes para usar max 2CPUs durante chequeos.
- data.table por defecto usa 1/2 de todos los CPUs de la máquina.

```
Flavor: r-devel-linux-x86_64-debian-gcc
Check: examples, Result: NOTE
  Examples with CPU time > 2.5 times elapsed time
                          user system elapsed ratio
  aum_line_search       12.349  0.322   1.935 6.548
  aum_line_search_grid 10.033  0.308   1.781 5.806
  aum_diffs_penalty     4.730  0.169   1.635 2.996
```

- Chequea la NOTA como arriba, usa el código R como en los ejemplos de arriba y testeos:

```
1  data.table::setDTthreads(2)
```

4/4Contribuyendo con data.table

Comunidad blog y encuesta

- La mascota de data.table es un león marino que ladra “R R R”
- La comunidad data.table tiene un nuevo blog, The Raft,

https://rdatatable-community.github.io/The-Raft/

Los leones marinos a menudo flotan juntos en la superficie del océano en grupos llamadas(balsas) ” rafts.” - Centro de Mamíferos Marinos.

- Por favor completa la encuesta.

https://tinyurl.com/datatable-survey

~10 minutos, cuentanos acerca del uso en data.table! (ayudanos a entender qué priorizar en el futuro)

Repositorio GitHub

- data.table tiene un activo *issues/Pull Request(PR)* de extracción (PR) https://github.com/Rdatatable/data.table/
- 1000+ open issues, 100+ open PRs
- si tu tienes algo de tiempo/interés,podríamos usar tu ayuda! -Es fácil contribuir: prueba reproducir en problemas (De mucha ayuda para saber si hay algún problemas que sean reproducible)
- Es una comunidad muy inclusiva luego de tu ingreso por primera vez en PR, serás invitado a unirte al grupo de github!
- Ahora se vienen tiempos muy exitantes para involucrarte,ya que actualmente estamos creando un formal Documento escrito que describe la gobernanza descentralizada del proyecto, #5676

Premios de Traducción

- En 2023-2025, la Fundación Nacional de Ciencias ha proporcionado fondos para apoyar y ampliar el ecosistema de usuarios y contribuyentes en torno a data.table
- 20 premios de traducción, de US$ 500 cada uno, para realizar documentación y mensajes más accesibles, ideas:
- Traducir errores/advertencias/mensajes (el paquete potools puede ayudar)
- Traducir las viñetas más importantes (introducción, importación, remodelación)
- Traducir otra documentación (hojas de referencia, diapositivas, etc.)
- Prioridad: portugués, español, chino, francés, ruso, árabe, hindi
  - Llamado para propuestas: https://rdatatable-community.github.io/The-Raft/

Premios en Viajes

- En 2023-2025, la Fundación Nacional de Ciencias ha proporcionado fondos para apoyar y ampliar el ecosistema de usuarios y contribuyentes en torno a data.table
- Ocho premios de viaje, 2700 dólares cada uno.
- Los candidatos deben dar una charla sobre data.table en una conferencia con una audiencia relevante (posibles usuarios o contribuyentes de data.table)
- Convocatoria de propuestas próximamente https://rdatatable-community.github.io/The-Raft/

Resumen de data.table

- Sintaxis concisa y consistente.
- Rápida , eficiente en memoria.
- No tiene dependencias (es fácil de instalar)
- No hay quiebres en los cambios (es fácil de actualizar -update-)
- Inclusive el usuario/desarrollador de la comunidad tiene oportunidades de contribuir:
- Premios en traducción, US$500 cada uno.
- Premios en viajes, US$2700 cada uno.

GRACIAS. ¿PREGUNTAS?

Mara Destéfanis
maragdestefanis@gmail.com

Fundado por el programa NSF POSE, proyecto #2303612. diapositivas adaptadas de Toby Dylan Hocking, Arun Srinivasan, y datatable-viñeta de introducción - gracias!