Vitesses d'exécution dans R : comparaisons de base R, dplyr et data.table

Antoine Sireyjol

14 février 2019

Je me présente

- Antoine Sireyjol, statisticien indépendant

Je me présente

- Antoine Sireyjol, statisticien indépendant
- Ancien salarié de la Drees : le service statistique du Ministère des Solidarités et de la santé

Je me présente

- Antoine Sireyjol, statisticien indépendant
- Ancien salarié de la Drees : le service statistique du Ministère des Solidarités et de la santé
- Travail depuis Toulouse sur la migration de leurs outils de SAS vers R (ou Python)

Je me présente

- Antoine Sireyjol, statisticien indépendant
- Ancien salarié de la Drees : le service statistique du Ministère des Solidarités et de la santé
- Travail depuis Toulouse sur la migration de leurs outils de SAS vers R (ou Python)
- Tests de comparaison d'instructions entre R et SAS mais aussi entre les différentes options de R

Plan de la présentation

Plan de la présentation

Plan de la présentation

Plan de la présentation

Plan de la présentation

Dplyr et data.table

Dplyr et le tidyverse

- Tidyverse : environnement d'analyse de données en R

Dplyr et le tidyverse

- Tidyverse : environnement d'analyse de données en R
- Propre format de données : le tibble

Dplyr et le tidyverse

- Tidyverse : environnement d'analyse de données en R
- Propre format de données : le tibble
- Syntaxe caractéristique et concurrente des fonctions de base R avec `dplyr`

Dplyr et le tidyverse

- Tidyverse : environnement d'analyse de données en R
- Propre format de données : le tibble
- Syntaxe caractéristique et concurrente des fonctions de base R avec `dplyr`
- Chaînage possible des instructions avec %>%

Dplyr et le tidyverse

- Tidyverse : environnement d'analyse de données en R
- Propre format de données : le tibble
- Syntaxe caractéristique et concurrente des fonctions de base R avec `dplyr`
- Chaînage possible des instructions avec %>%
- Très lisible et optimisé

Syntaxe dplyr (1)

La grammaire `dplyr` s'appuie sur des fonctions aux noms explicites :

- `mutate(data, newvar1 = fonction(var1, var2...))` et `transmute(data, newvar1 = fonction(var1, var2...))` créent de nouvelles variables

Syntaxe dplyr (1)

La grammaire `dplyr` s'appuie sur des fonctions aux noms explicites :

- `mutate(data, newvar1 = fonction(var1, var2...))` et `transmute(data, newvar1 = fonction(var1, var2...))` créent de nouvelles variables
- `filter(data, condition)` sélectionne au sein d'une table certaines observations.

Syntaxe dplyr (1)

La grammaire `dplyr` s'appuie sur des fonctions aux noms explicites :

- `mutate(data, newvar1 = fonction(var1, var2...))` et `transmute(data, newvar1 = fonction(var1, var2...))` créent de nouvelles variables
- `filter(data, condition)` sélectionne au sein d'une table certaines observations.
- `arrange(data, var1, descending var2,...)` trie une base selon une ou plusieurs variables.

Syntaxe dplyr (1)

La grammaire `dplyr` s'appuie sur des fonctions aux noms explicites :

- `mutate(data, newvar1 = fonction(var1, var2...))` et `transmute(data, newvar1 = fonction(var1, var2...))` créent de nouvelles variables
- `filter(data, condition)` sélectionne au sein d'une table certaines observations.
- `arrange(data, var1, descending var2,...)` trie une base selon une ou plusieurs variables.
- `select(data, var1 : varX)` sélectionne certaines variables dans une base.

Syntaxe dplyr (1)

La grammaire `dplyr` s'appuie sur des fonctions aux noms explicites :

- `mutate(data, newvar1 = fonction(var1, var2...))` et `transmute(data, newvar1 = fonction(var1, var2...))` créent de nouvelles variables
- `filter(data, condition)` sélectionne au sein d'une table certaines observations.
- `arrange(data, var1, descending var2,...)` trie une base selon une ou plusieurs variables.
- `select(data, var1 : varX)` sélectionne certaines variables dans une base.
- `group_by(data, var)` regroupe une table par une variable

Syntaxe dplyr (1)

La grammaire `dplyr` s'appuie sur des fonctions aux noms explicites :

- `mutate(data, newvar1 = fonction(var1, var2...))` et `transmute(data, newvar1 = fonction(var1, var2...))` créent de nouvelles variables
- `filter(data, condition)` sélectionne au sein d'une table certaines observations.
- `arrange(data, var1, descending var2,...)` trie une base selon une ou plusieurs variables.
- `select(data, var1 : varX)` sélectionne certaines variables dans une base.
- `group_by(data, var)` regroupe une table par une variable
- `summarise(data, newvar1 = mean(var1), newvar2 = sum(var2))` réalise toute sorte d'opérations statistiques sur une table.

Syntaxe dplyr (2)

- Possibilité de chaîner ces opérations : l'opérateur %>%

Syntaxe dplyr (2)

- Possibilité de chaîner ces opérations : l'opérateur %>%
- `fonction(data, params...)` est équivalent à `data %>% fonction(params...)`

Syntaxe dplyr (2)

- Possibilité de chaîner ces opérations : l'opérateur %>%
- `fonction(data, params...)` est équivalent à `data %>% fonction(params...)`
- Exemple :

Syntaxe dplyr (2)

```
library(tidyverse)
# on crée un data frame avec 100 lignes,
# chaque individu appartenant à un des 50 groupes
df <- data.frame(id1 = c(1:100),
                 idgpe = sample(50))

# on y applique les instructions de dplyr
df %>% as_tibble() %>%
  mutate(var = rnorm(100)) %>%
  group_by(idgpe) %>%
  summarise(var_mean = mean(var)) -> output_tibble
print(head(output_tibble), 5)
```

Syntaxe dplyr (2)

```
## # A tibble: 5 x 2
##   idgpe var_mean
##   <int>    <dbl>
## 1     1   0.0712
## 2     2  -0.204
## 3     3   1.01
## 4     4   0.324
## 5     5  -0.409
```

Data.table

- Format optimisé de data.frame

Data.table

- Format optimisé de data.frame
- Complémentaire à base R

Data.table

- Format optimisé de data.frame
- Complémentaire à base R
- Optimisation de l'opérateur [

Data.table

- Format optimisé de data.frame
- Complémentaire à base R
- Optimisation de l'opérateur [
- Chaînage possible des instructions

Data.table

- Format optimisé de data.frame
- Complémentaire à base R
- Optimisation de l'opérateur [
- Chaînage possible des instructions
- Plus lisible, plus rapide que base R

Syntaxe data.table (1)

- l'opérateur `[` appliqué au data.table change de signification et devient :

```
DT[i, j, by]
```

Syntaxe data.table (1)

- l'opérateur `[` appliqué au data.table change de signification et devient :

```
DT[i, j, by]
```

- `i` permet de sélectionner des lignes de `DT`

Syntaxe data.table (1)

- l'opérateur `[` appliqué au data.table change de signification et devient :

```
DT[i, j, by]
```

- `i` permet de sélectionner des lignes de `DT`
- `j` permet de créer des variables ou d'en sélectionner

Syntaxe data.table (1)

- l'opérateur `[` appliqué au data.table change de signification et devient :

```
DT[i, j, by]
```

- `i` permet de sélectionner des lignes de `DT`
- `j` permet de créer des variables ou d'en sélectionner
- `by` permet de regrouper les traitements selon les modalités d'une variable définie

Syntaxe data.table (1)

- l'opérateur `[` appliqué au data.table change de signification et devient :

```
DT[i, j, by]
```

- `i` permet de sélectionner des lignes de `DT`
- `j` permet de créer des variables ou d'en sélectionner
- `by` permet de regrouper les traitements selon les modalités d'une variable définie
- L'usage de `[` permet de chaîner les opérations :

Syntaxe data.table (2)

```
library(data.table)
# on convertit notre data frame
# précédemment créé en data.table
dt <- as.data.table(df)

# on y applique les même instructions
dt[, var := rnorm(100)
   ][, list(var_mean = mean(var)),
   by = idgpe] -> output_dt

print(head(output_dt, 5))
```

Syntaxe data.table (2)

```
##     idgpe    var_mean
## 1:     29 -0.02054862
## 2:     36 -0.32109472
## 3:     18 -1.11604122
## 4:     50 -0.05979796
## 5:     43 -1.71268615
```

Comparaisons avec base R

`dplyr` et `data.table` présentent un certain nombre d'avantages par rapport à l'usage de base R exclusivement :

- Plus lisibles et moins verbeux, grâce notamment au chaînage

Comparaisons avec base R

`dplyr` et `data.table` présentent un certain nombre d'avantages par rapport à l'usage de base R exclusivement :

- Plus lisibles et moins verbeux, grâce notamment au chaînage
- Pensés pour l'analyse de données

Comparaisons avec base R

`dplyr` et `data.table` présentent un certain nombre d'avantages par rapport à l'usage de base R exclusivement :

- Plus lisibles et moins verbeux, grâce notamment au chaînage
- Pensés pour l'analyse de données
- Instructions optimisées et bien plus rapides que base R

Comparaison des vitesses d'exécution

Étude de cas avec `nycflights13`

- Base `flights` : heures de départ et d'arrivée selon les aéroports + retards au départ et à l'arrivée

Étude de cas avec `nycflights13`

- Base `flights` : heures de départ et d'arrivée selon les aéroports + retards au départ et à l'arrivée
- 336776 lignes et 19 variables

Étude de cas avec `nycflights13`

- Base `flights` : heures de départ et d'arrivée selon les aéroports + retards au départ et à l'arrivée
- 336776 lignes et 19 variables
- Base `weather` : indications météo, heure par heure, dans chaque aéroport

Étude de cas avec `nycflights13`

- Base `flights` : heures de départ et d'arrivée selon les aéroports + retards au départ et à l'arrivée
- 336776 lignes et 19 variables
- Base `weather` : indications météo, heure par heure, dans chaque aéroport
- 26115 lignes et 15 variables

Étude de cas avec `nycflights13`

- Base `flights` : heures de départ et d'arrivée selon les aéroports + retards au départ et à l'arrivée
- 336776 lignes et 19 variables
- Base `weather` : indications météo, heure par heure, dans chaque aéroport
- 26115 lignes et 15 variables
- On crée `flights_dt` et `weather_dt` avec `as.data.table`

Étude de cas avec `nycflights13`

- Base `flights` : heures de départ et d'arrivée selon les aéroports + retards au départ et à l'arrivée
- 336776 lignes et 19 variables
- Base `weather` : indications météo, heure par heure, dans chaque aéroport
- 26115 lignes et 15 variables
- On crée `flights_dt` et `weather_dt` avec `as.data.table`
- Étude de cas : fusion des deux tables pour expliquer retards à l'arrivée et au départ en fonction de la météo

Étude de cas avec nycflights13 - Base R

```
flights_time_hour <- aggregate.data.frame(
  list(arr_delay = flights$arr_delay,
       dep_delay = flights$dep_delay),
  list(time_hour = flights$time_hour,
       origin = flights$origin),
  mean)
merge_base <- merge(weather, flights_time_hour,
                    by = c("time_hour", "origin"),
                    sort = FALSE)
```

Étude de cas avec nycflights13 - dplyr

```
flights %>% group_by(time_hour, origin) %>%
  summarise(arr_delay = mean(arr_delay),
            dep_delay = mean(dep_delay)) %>%
  inner_join(weather, by = c("time_hour", "origin")
             ) -> merge_dplyr
```

Étude de cas avec nycflights13 - data.table

```
merge_DT <- merge(
  flights_dt[, list(arr_delay = mean(arr_delay),
                    dep_delay = mean(dep_delay)),
             by = list(time_hour, origin)],
  weather_dt,
  by = c("time_hour", "origin"))
```

Comparaisons des vitesses de ces instructions

Le package `microbenchmark` nous permet de comparer la vitesse de ces instructions :

```
## Unit: milliseconds
##         expr       min         lq       mean     median
##       base R 1562.0863 1709.79092 1792.75304 1766.92559
##        dplyr  117.8949  124.27666  131.65595  126.27915
##   data.table   53.0910   57.73143   64.51634   59.51888
##           uq       max neval
##  1810.16286 2212.48120    10
##   140.83816  151.26419    10
##    69.71906   91.03932    10
```

Comparaisons du groupage en fonction du nombre d'observations

- Avantage net de dplyr et data.table sur base R, et avantage à data.table sur cet exemple

Comparaisons du groupage en fonction du nombre d'observations

- Avantage net de dplyr et data.table sur base R, et avantage à data.table sur cet exemple
- Qu'en est-il quand on fait varier le nombre d'observations?

Comparaisons du groupage en fonction du nombre d'observations

- Avantage net de dplyr et data.table sur base R, et avantage à data.table sur cet exemple
- Qu'en est-il quand on fait varier le nombre d'observations?
- Comparaisons des vitesses d'agrégation en faisant varier le nombre d'observations et le nombre de groupes

Comparaisons du groupage en fonction du nombre d'observations

- Avantage net de dplyr et data.table sur base R, et avantage à data.table sur cet exemple
- Qu'en est-il quand on fait varier le nombre d'observations?
- Comparaisons des vitesses d'agrégation en faisant varier le nombre d'observations et le nombre de groupes
- Les instructions testées :

Comparaisons du groupage en fonction du nombre d'observations

```
# Pour dplyr
datatib %>% group_by(y)
%>% summarise(x = mean(x))

# Pour data.table
dataDT[, .(x = mean(x)),
       by = .(y = y)]

# Pour base R
tap <- tapply(test$x, test$y, mean)
data.frame(x = tap, y = names(tap))
```

Résultats en fonction des nombres de lignes et de groupes

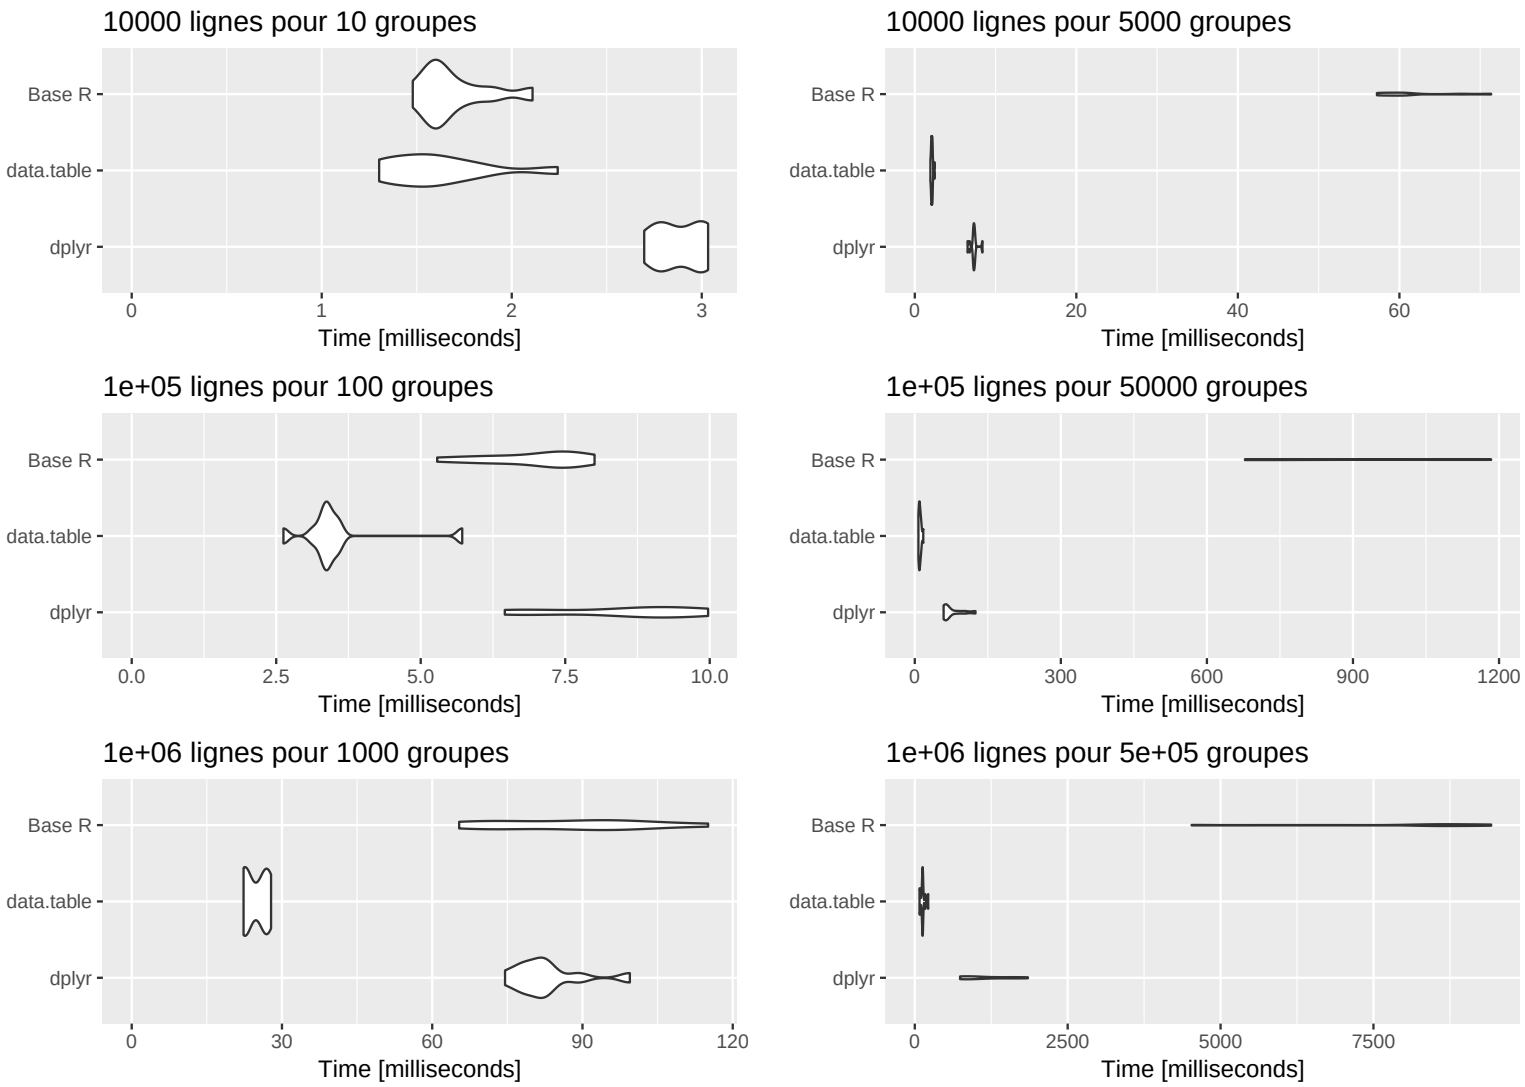

#

Conclusions sur les comparaisons

Conclusions

- Dplyr et data.table : + rapides et + faciles d'utilisation que base R pour l'analyse de données

Conclusions

- Dplyr et data.table : + rapides et + faciles d'utilisation que base R pour l'analyse de données
- Choix entre dplyr et data.table dépend de différents facteurs :
  . Type de base de données en entrée . Profil des personnes qui codent . Importance accordée à la vitesse d'exécution

Conclusions

- Dplyr et data.table : + rapides et + faciles d'utilisation que base R pour l'analyse de données
- Choix entre dplyr et data.table dépend de différents facteurs :
  . Type de base de données en entrée . Profil des personnes qui codent . Importance accordée à la vitesse d'exécution
- Intéressant de faire des tests sur ses scripts pour voir comment ils peuvent être optimisés

Quelques astuces d'optimisation

Utiliser les fonctions *apply plutôt que les boucles

- Important de vectoriser ses instructions

Utiliser les fonctions *apply plutôt que les boucles

- Important de vectoriser ses instructions
- *apply permet d'appliquer une fonction à un ensemble d'éléments

Utiliser les fonctions *apply plutôt que les boucles

- Important de vectoriser ses instructions
- *apply permet d'appliquer une fonction à un ensemble d'éléments
- `apply(matrice, i, f())` applique f à l'ensemble des lignes (i = 1) ou des colonnes (i = 2) de la matrice

Utiliser les fonctions *apply plutôt que les boucles

- Important de vectoriser ses instructions
- *apply permet d'appliquer une fonction à un ensemble d'éléments
- `apply(matrice, i, f())` applique f à l'ensemble des lignes (i = 1) ou des colonnes (i = 2) de la matrice
- `lapply(X, f())` applique f à chacun des éléments du vecteur ou de la liste X

Utiliser les fonctions *apply plutôt que les boucles

- Important de vectoriser ses instructions
- *apply permet d'appliquer une fonction à un ensemble d'éléments
- `apply(matrice, i, f())` applique f à l'ensemble des lignes (i = 1) ou des colonnes (i = 2) de la matrice
- `lapply(X, f())` applique f à chacun des éléments du vecteur ou de la liste X
- Comparaisons avec une boucle :

lapply et boucle

```
# On crée une matrice de 10 000 lignes et 25 colonnes
data <- matrix(1:250000, ncol = 25)

# On veut le résultat de la somme de chaque ligne
# Avec une boucle
boucle_results <- c()
for (i in 1:nrow(data)){
  boucle_results <- append(boucle_results, sum(data[i, ]))
  }

# Avec apply
apply_results <- apply(data, 1, sum)

identical(apply_results, boucle_results)
```

```
## [1] TRUE
```

lapply et boucle : microbenchmark

```
## Unit: milliseconds
##    expr       min        lq      mean    median        uq
##  boucle 135.23915 138.18372 165.49520 161.47091 183.97360
##   apply  12.32783  13.09668  16.25538  15.80089  16.60331
##         max neval
##  236.59129    20
##   24.63688    20
```

Éviter ifelse

```
# Fonction ifelse
flights$gros_retard <- ifelse(flights$arr_delay > 30,
                              "oui", "non")

# Sans ifelse
flights$gros_retardbis <- "non"
flights$gros_retardbis[flights$arr_delay > 30] <-  "oui"
```

Éviter ifelse - microbenchmark

```
## Unit: milliseconds
##          expr         min          lq      mean      median
##        ifelse 145.619669 184.310382 200.56859 194.340750
##  sans ifelse   4.867984   7.742865  12.28362   8.037835
##           uq      max neval
##  211.783456 324.636   100
##    9.695008 179.076   100
```

Dplyr : pas de création de variable à l'intérieur de summarise()

```
# Avec mutate
flights %>% mutate(propor_delay = arr_delay / air_time) %>%
group_by(time_hour) %>%
summarise(propor_delay = mean(propor_delay)
          ) -> output_dyp

# Sans mutate
flights %>% group_by(time_hour) %>%
summarise(propor_delay = mean(arr_delay / air_time)
          ) -> output_dyp2
```

Dplyr : pas de création de variable à l'intérieur de summarise() - microbenchmark

```
## Unit: milliseconds
##                 expr       min        lq      mean    median
##       dplyr_mutate  51.26316  51.63749  52.17168  52.03685
##  dplyr_sans_mutate 516.77483 526.39190 576.59482 533.52037
##         uq      max neval
##   52.38387  53.7566    10
##  539.72325 970.5435    10
```

Dplyr : group_by par factor plutôt que caractère

```
flights$originfac <- as.factor(flights$origin)

# group by character
flights %>% group_by(origin) %>%
  summarize(mean_delay = mean(arr_delay, na.rm = TRUE)
            ) -> out_char

# group by factor
flights %>% group_by(originfac) %>%
  summarize(mean_delay = mean(arr_delay, na.rm = TRUE)
            ) -> out_fact
```

Dplyr : group_by par factor plutôt que caractère - microbenchmark

```
## Unit: milliseconds
##                  expr      min       lq     mean   median
##  group by character 28.17139 31.59269 33.70611 32.75180
##     group by factor 24.84964 26.06365 29.14373 27.71229
##         uq     max neval
##  33.97889 55.6163    20
##  28.53206 46.1972    20
```

Références

Références

- Formation R perfectionnement, M. Chevalier

Références

- Formation R perfectionnement, M. Chevalier
- Introduction à R et au tidyverse, J.Barnier

Références

- Formation R perfectionnement, M. Chevalier
- Introduction à R et au tidyverse, J.Barnier
- Manipulations avancées avec data.table, J. Larmarange

Références

- Formation R perfectionnement, M. Chevalier
- Introduction à R et au tidyverse, J.Barnier
- Manipulations avancées avec data.table, J. Larmarange
- Discussion stackoverflow dplyr vs data.table

Références

- Formation R perfectionnement, M. Chevalier
- Introduction à R et au tidyverse, J.Barnier
- Manipulations avancées avec data.table, J. Larmarange
- Discussion stackoverflow dplyr vs data.table
- Pour des benchmarks data.table, dplyr et python : Benchmarks : Grouping

Références

- Formation R perfectionnement, M. Chevalier
- Introduction à R et au tidyverse, J.Barnier
- Manipulations avancées avec data.table, J. Larmarange
- Discussion stackoverflow dplyr vs data.table
- Pour des benchmarks data.table, dplyr et python : Benchmarks : Grouping
- https://antoinesir.rbind.io