THINKR

Le 'tidyeval'

ou comment programmer dans le {tidyverse}

Vincent Guyader

Data Scientist, expert logiciel R.

- https://rtask.thinkr.fr
- https://github.com/ThinkR-open
- https://twitter.com/thinkr_fr

THINKR

Vincent Guyader
Codeur Fou, formateur et expert logiciel R

Diane Beldame
Dompteuse de ~~dragons~~ données, formatrice logiciel R

Colin Fay
Data scientist et R hacker

Sébastien Rochette
Modélisateur, Formateur R, Joueur de cartographies

Cervan Girard
Le nouveau

C'est quoi le {tidyverse} ?

Tidyverse

Packages Articles Learn Help Contribute

R packages for data science

The tidyverse is an opinionated collection of R packages designed for data science. All packages share an underlying philosophy and common APIs.

Install the complete tidyverse with:

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

Écrire comme on parle avec le %>%

- à prononcer "païpe"
- raccourci clavier : "Ctrl + Shift + M"

Une question de grammaire

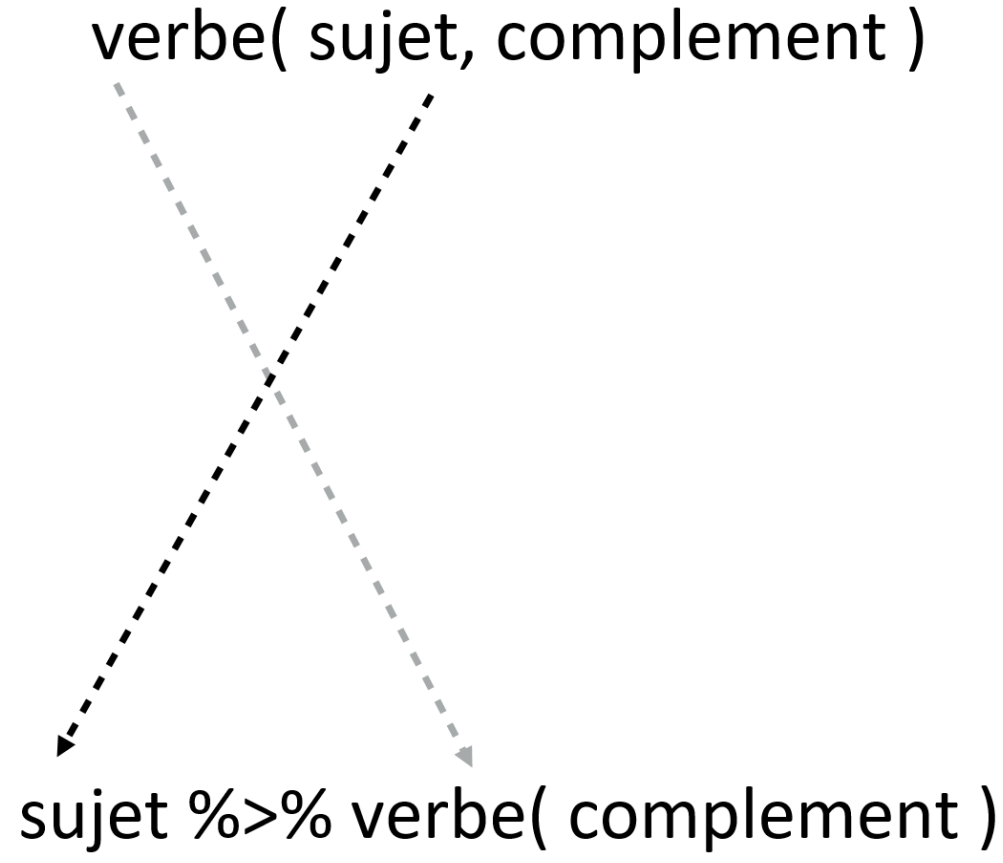

`arrange()` trie les observations...

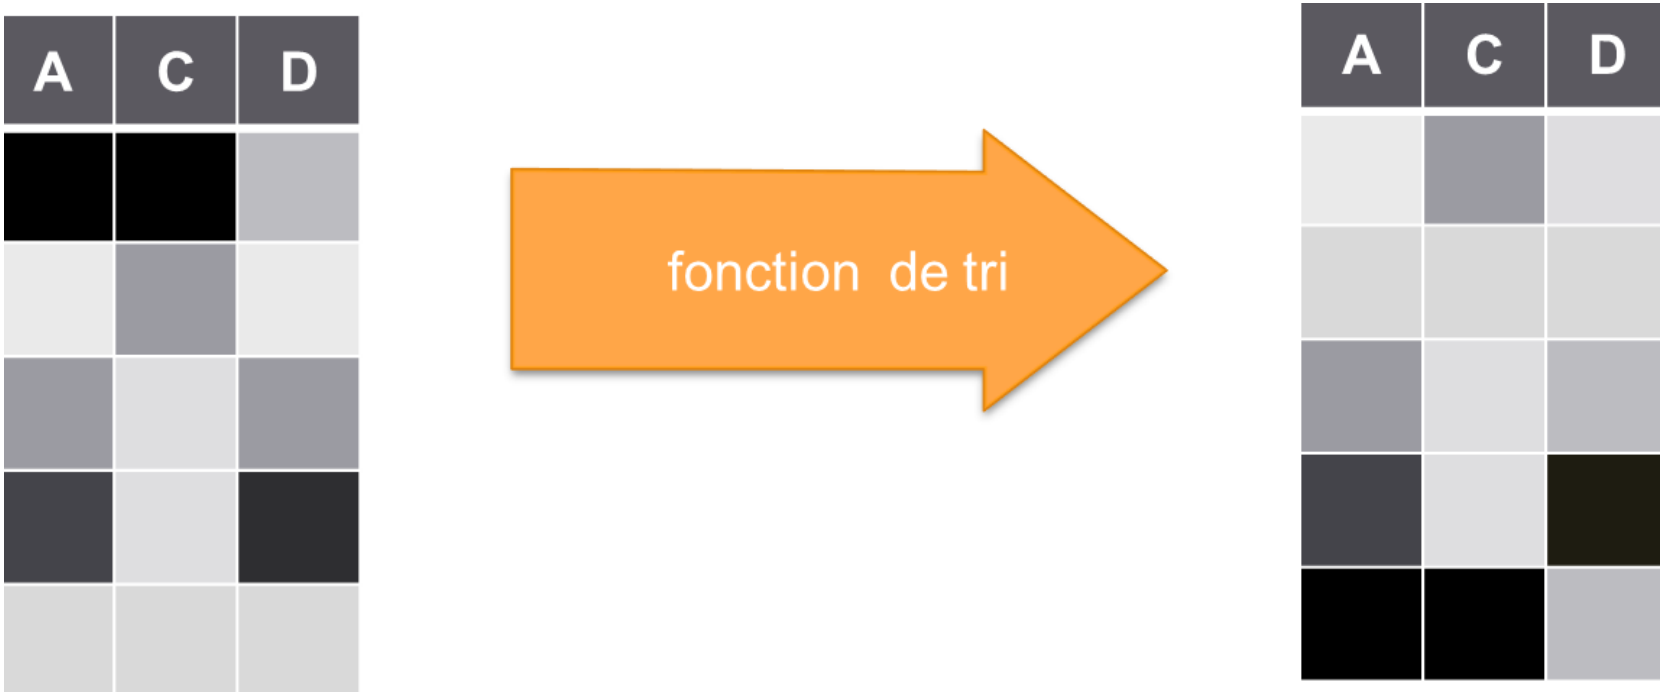


```
iris %>% arrange( Sepal.Length )
iris %>% arrange( desc(Sepal.Length), Petal.Length )
```

`filter()` réduit la hauteur du dataset

lignes	A	B	C
1			
2			
3			
4			

lignes	A	B	C
1			
3			

```
iris %>% filter( Species == "virginica" )
iris %>% filter( Species == "virginica", Petal.Width < 3 )
```

Réduire le jeu de données en largeur : `select()`

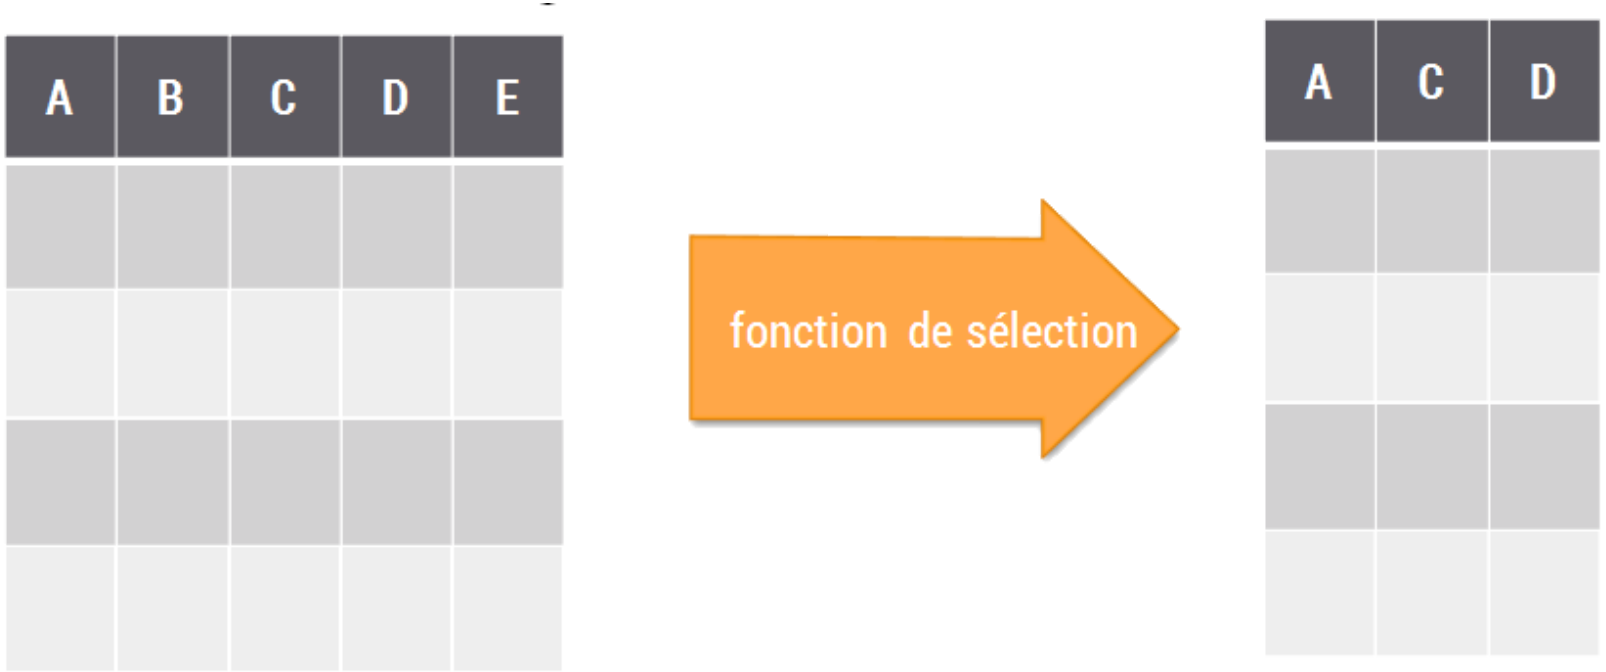


```
iris %>% select( Species, Sepal.Width, Petal.Width )
```

`mutate()` pour transformer ou créer des variables

`mutate()` modifie le jeu de données en largeur pour y adjoindre des colonnes, et/ou modifier des variables existantes.

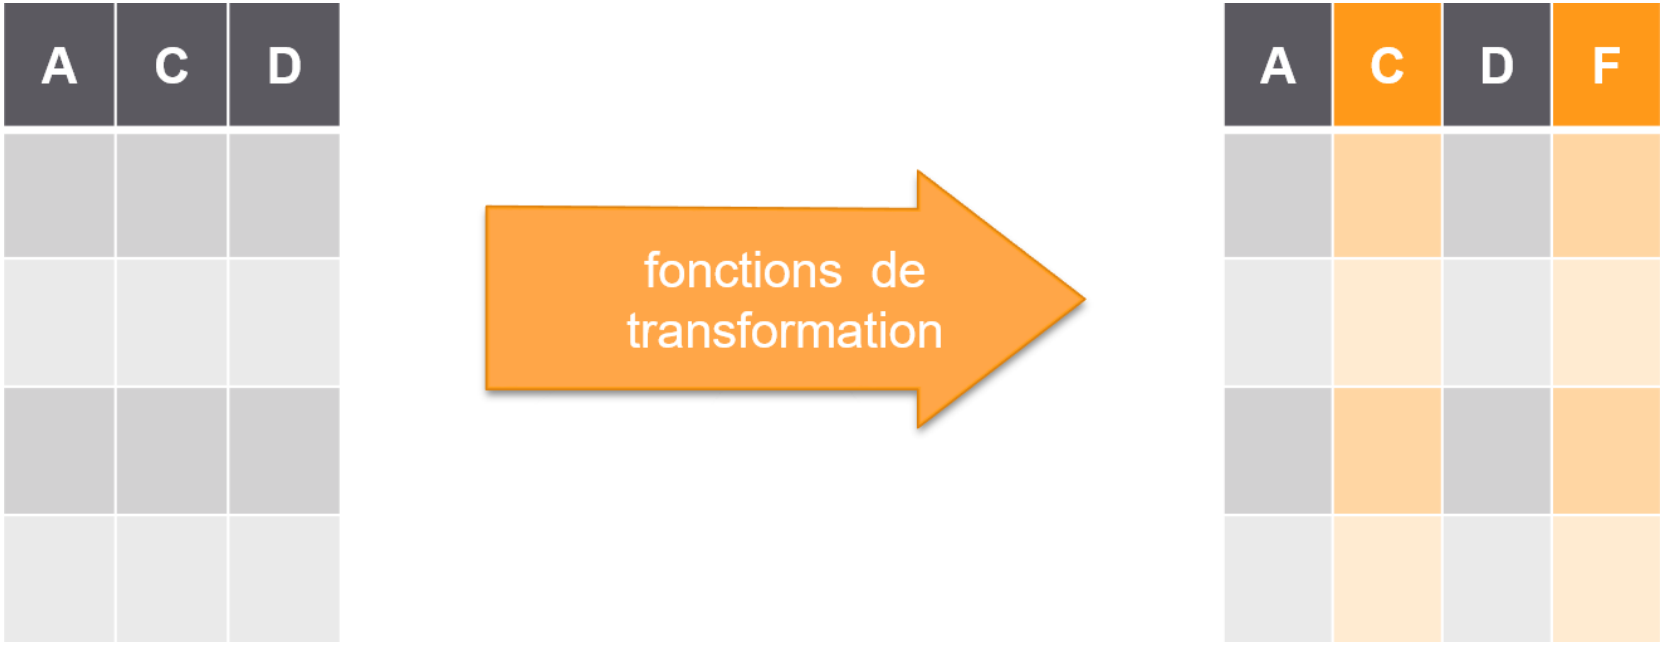


```
iris %>%
  mutate( ratio_sepal = Sepal.Length / Sepal.Width)
```

Résumer l'information avec : `summarise()`

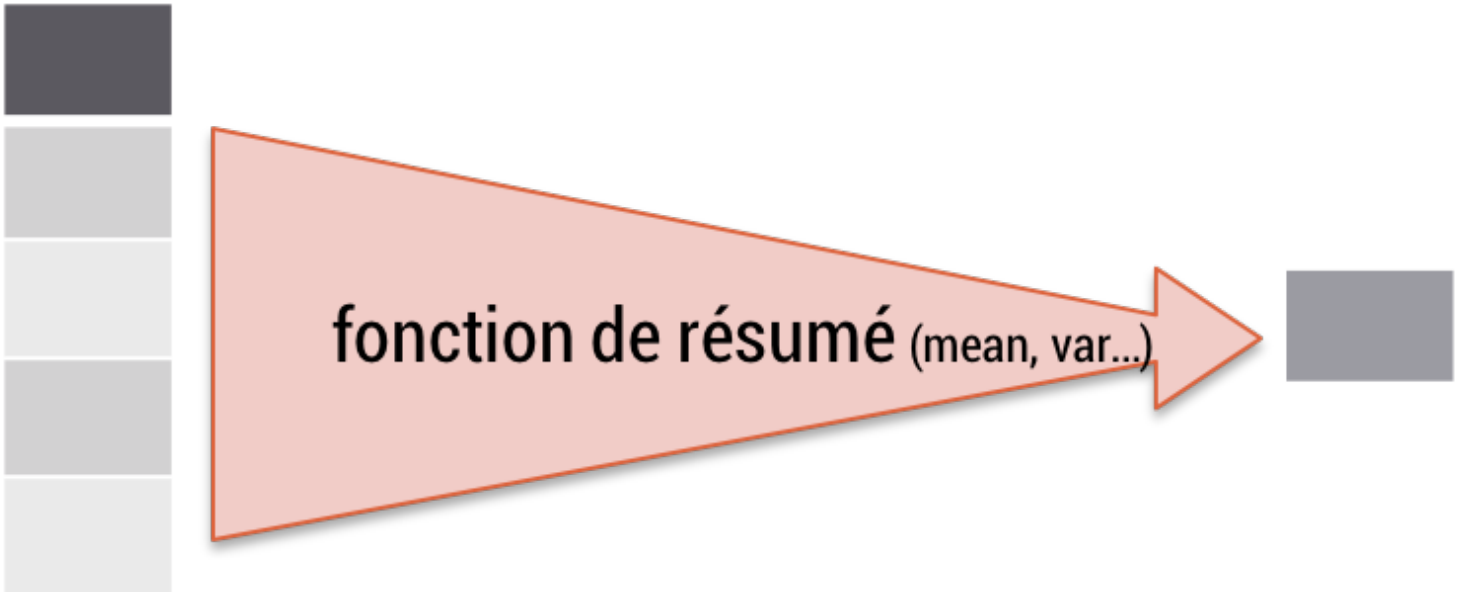


```
iris %>%
  summarise(  moyenne = mean( Sepal.Length )  )
```

Résumer l'information **par groupe** avec : `group_by` & `summarise()`

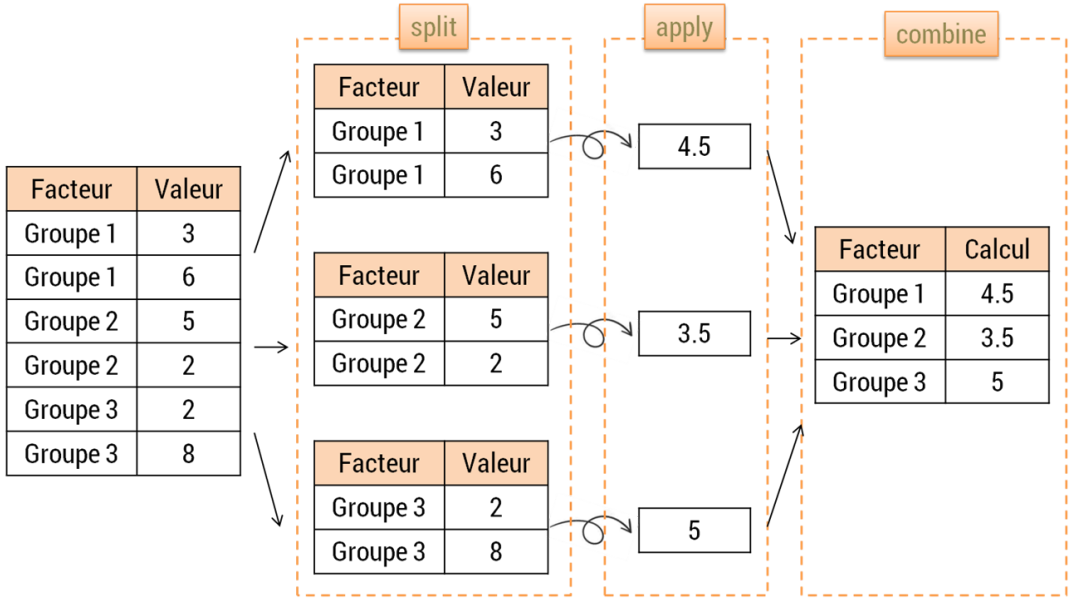


```
iris %>%
  group_by( Species ) %>%
  summarise(  moyenne_Sepal.Length = mean( Sepal.Length )  )
```

En pratique

```
iris %>%
  arrange( Sepal.Width ) %>%
  filter( Sepal.Width >3 ) %>%
  select( -Sepal.Width ) %>%
  group_by( Species ) %>%
  summarise( nombre = n() )
```

```
#> # A tibble: 3 x 2
#>   Species    nombre
#>   <fct>       <int>
#> 1 setosa         42
#> 2 versicolor      8
#> 3 virginica      17
```

> *...C'est simple, (basique) et lisible !*

Faisons une fonction du script précédent

Faisons une fonction du script précédent

```
filter_and_count <- function(dataset, variable){

  dataset %>%
  arrange( variable ) %>%
  filter( variable > 3 ) %>%
  select( -variable ) %>%
  group_by( Species ) %>%
  summarise( nombre = n() )

}
```

Faisons une fonction du script précédent

```
filter_and_count <- function(dataset, variable){

  dataset %>%
  arrange( variable ) %>%
  filter( variable > 3 ) %>%
  select( -variable ) %>%
  group_by( Species ) %>%
  summarise( nombre = n() )

}
```

```
iris %>% filter_and_count(Sepal.Length)
```

```
#> Error in arrange_impl(.data, dots): objet 'Sepal.Length' introuvable
```

Faisons une fonction du script précédent

```
filter_and_count <- function(dataset, variable){

  dataset %>%
  arrange( variable ) %>%
  filter( variable > 3 ) %>%
  select( -variable ) %>%
  group_by( Species ) %>%
  summarise( nombre = n() )

}
```

```
iris %>% filter_and_count(Sepal.Length)
```

```
#> Error in arrange_impl(.data, dots): objet 'Sepal.Length' introuvable
```

```
iris %>% filter_and_count("Sepal.Length")
```

```
#> Error in arrange_impl(.data, dots): incorrect size (1) at position 1,
expecting : 150
```

NSE de quoi ??

Quelle est la différence entre ces 2 instructions ?

```
library("dplyr")
```

et

```
library(dplyr)
```

NSE de quoi ??

Quelle est la différence entre ces 2 instructions ?

```
library("dplyr")
```

et

```
library(dplyr)
```

Ok, mais alors que fait le code suivant ?

```
dplyr <- "data.table"
library(dplyr)
```

NSE de quoi ??

Quelle est la différence entre ces 2 instructions ?

```
library("dplyr")
```

et

```
library(dplyr)
```

Ok, mais alors que fait le code suivant ?

```
dplyr <- "data.table"
library(dplyr)
```

Et celui ci ?

```
y <- "data.table"
library(y)
```

NSE de quoi ??

Quelle est la différence entre ces 2 instructions ?

```
library("dplyr")
```

et

```
library(dplyr)
```

Ok, mais alors que fait le code suivant ?

```
dplyr <- "data.table"
library(dplyr)
```

Et celui ci ?

```
y <- "data.table"
library(y)
```

La fonction `library` utilise le paramètre `character.only`

```
dplyr <- "data.table"
library(dplyr) #charge {dplyr}
library(dplyr,character.only = TRUE) #charge {data.table}
```

NSE + {dplyr} dans ses propres fonctions ?

Dans {dplyr}, tous les paramètres (sauf `.data`) sont évalués de manière non standard

NSE + {dplyr} dans ses propres fonctions ?

Dans {dplyr}, tous les paramètres (sauf `.data`) sont évalués de manière non standard

Pour créer une fonction qui utilise et se comporte comme les fonctions du {tidyverse}, il faut utiliser conjointement 2 outils :

NSE + {dplyr} dans ses propres fonctions ?

Dans {dplyr}, tous les paramètres (sauf `.data`) sont évalués de manière non standard

Pour créer une fonction qui utilise et se comporte comme les fonctions du {tidyverse}, il faut utiliser conjointement 2 outils :

- La fonction **enquo()**

NSE + {dplyr} dans ses propres fonctions ?

Dans {dplyr}, tous les paramètres (sauf `.data`) sont évalués de manière non standard

Pour créer une fonction qui utilise et se comporte comme les fonctions du {tidyverse}, il faut utiliser conjointement 2 outils :

- La fonction **enquo()**
- Et l'opérateur **!!** *(à prononcer bang-bang)*

Construisons la fonction

```
filter_and_count <- function(dataset, variable){



  dataset %>%
  arrange( variable ) %>%
  filter( variable > 3 ) %>%
  select( -variable ) %>%
  group_by( Species ) %>%
  summarise( nombre = n() )

}
```

Construisons la fonction

```
filter_and_count <- function(dataset, variable){

  variable <- enquo(variable) # Pour 'quoter' la variable

  dataset %>%
  arrange( variable ) %>%
  filter( variable > 3 ) %>%
  select( -variable ) %>%
  group_by( Species ) %>%
  summarise( nombre = n() )

}
```

Construisons la fonction

```
filter_and_count <- function(dataset, variable){

  variable <- enquo(variable) # Pour 'quoter' la variable

  dataset %>%
  arrange( !! variable ) %>% # Pour 'unquoter' la variable
  filter( !! variable > 3 ) %>%
  select( - !! variable ) %>%
  group_by( Species ) %>%
  summarise( nombre = n() )

}
```

Construisons la fonction

```
filter_and_count <- function(dataset, variable, seuil = 3){

  variable <- enquo(variable) # Pour 'quoter' la variable

  dataset %>%
  arrange( !! variable ) %>% # Pour 'unquoter' la variable
  filter( !! variable > seuil ) %>%
  select( - !! variable ) %>%
  group_by( Species ) %>%
  summarise( nombre = n() )

}
```

Ca marche plutôt bien

```
iris %>%
filter_and_count(Sepal.Width)
```

```
#> # A tibble: 3 x 2
#>   Species    nombre
#>   <fct>       <int>
#> 1 setosa         42
#> 2 versicolor      8
#> 3 virginica      17
```

Ca marche plutôt bien

```
iris %>%
filter_and_count(Sepal.Width)
```

```
#> # A tibble: 3 x 2
#>   Species    nombre
#>   <fct>       <int>
#> 1 setosa         42
#> 2 versicolor      8
#> 3 virginica      17
```

```
iris %>%
filter_and_count(Petal.Length)
```

```
#> # A tibble: 2 x 2
#>   Species    nombre
#>   <fct>       <int>
#> 1 versicolor     49
#> 2 virginica      50
```

Ca marche plutôt bien

```
iris %>%
filter_and_count(Sepal.Width)
```

```
#> # A tibble: 3 x 2
#>   Species    nombre
#>   <fct>       <int>
#> 1 setosa         42
#> 2 versicolor      8
#> 3 virginica      17
```

```
iris %>%
filter_and_count(Sepal.Length,
seuil = 5.3)
```

```
#> # A tibble: 3 x 2
#>   Species    nombre
#>   <fct>       <int>
#> 1 setosa         10
#> 2 versicolor     45
#> 3 virginica      49
```

```
iris %>%
filter_and_count(Petal.Length)
```

```
#> # A tibble: 2 x 2
#>   Species    nombre
#>   <fct>       <int>
#> 1 versicolor     49
#> 2 virginica      50
```

Rajoutons un paramètre...

...pour contrôler le nom de la colonne `nombre`

```
iris %>% filter_and_count(Sepal.Width, nom = comptage)
```

```
#> # A tibble: 3 x 2
#>   Species    comptage
#>   <fct>         <int>
#> 1 setosa           42
#> 2 versicolor        8
#> 3 virginica        17
```

Comment faire cela ?

Rajoutons un paramètre...

```
filter_and_count <- function(dataset, variable, seuil = 3, nom = nombre){

  variable <- enquo(variable)

  dataset %>%
    arrange( !! variable ) %>%
    filter( !! variable > seuil ) %>%
    select( - !! variable ) %>%
    group_by( Species ) %>%
    summarise(  nom   = n() )
}
```

Rajoutons un paramètre...

```
filter_and_count <- function(dataset, variable, seuil = 3, nom = nombre){

  variable <- enquo(variable)

  dataset %>%
    arrange( !! variable ) %>%
    filter( !! variable > seuil ) %>%
    select( - !! variable ) %>%
    group_by( Species ) %>%
    summarise(  nom   = n() )
}
```

```
iris %>% filter_and_count(Sepal.Width, nom = comptage)
```

```
#> # A tibble: 3 x 2
#>   Species      nom
#>   <fct>      <int>
#> 1 setosa        42
#> 2 versicolor     8
#> 3 virginica     17
```

Rajoutons un paramètre...

```
filter_and_count <- function(dataset, variable, seuil = 3, nom = nombre){

  variable <- enquo(variable)
  nom <- enquo(nom)
  dataset %>%
    arrange( !! variable ) %>%
    filter( !! variable > seuil ) %>%
    select( - !! variable ) %>%
    group_by( Species ) %>%
    summarise(  !! nom   = n() )
}
```

```
# Error: unexpected '=' in:
# "    group_by( Species ) %>%
#     summarise(  !! nom   ="
# Error: unexpected '}' in "}"
```

Rajoutons un paramètre...

```
filter_and_count <- function(dataset, variable, seuil = 3, nom = nombre){

  variable <- enquo(variable)
  nom <- enquo(nom)
  dataset %>%
    arrange( !! variable ) %>%
    filter( !! variable > seuil ) %>%
    select( - !! variable ) %>%
    group_by( Species ) %>%
    summarise( !! nom := n() )
}
```

Rajoutons un paramètre...

```
filter_and_count <- function(dataset, variable, seuil = 3, nom = nombre){

  variable <- enquo(variable)
  nom <- enquo(nom)
  dataset %>%
    arrange( !! variable ) %>%
    filter( !! variable > seuil ) %>%
    select( - !! variable ) %>%
    group_by( Species ) %>%
    summarise( !! nom := n() )
}
```

```
iris %>% filter_and_count(Sepal.Width, nom = comptage)
```

```
#> Error: The LHS of `:=` must be a string or a symbol
```

Rajoutons un paramètre...

```
filter_and_count <- function(dataset, variable, seuil = 3, nom = nombre){

  variable <- enquo(variable)
  nom <- enquo(nom)
  dataset %>%
    arrange( !! variable ) %>%
    filter( !! variable > seuil ) %>%
    select( - !! variable ) %>%
    group_by( Species ) %>%
    summarise( !! quo_name(nom) := n() )
}
```

```
iris %>% filter_and_count(Sepal.Width, nom = comptage)
```

```
#> # A tibble: 3 x 2
#>   Species    comptage
#>   <fct>         <int>
#> 1 setosa           42
#> 2 versicolor        8
#> 3 virginica        17
```

Et Si ma fonction utilise les dots : `...` ?

Pour gérer le cas où une fonction doit être capable de prendre un nombre indéterminé de paramètres, il faut utiliser classiquement les `...` accompagnés de :

- la fonction **quos()**

Et Si ma fonction utilise les dots : `...` ?

Pour gérer le cas où une fonction doit être capable de prendre un nombre indéterminé de paramètres, il faut utiliser classiquement les `...` accompagnés de :

- la fonction **quos()**
- l'opérateur **!!!** *(bang-bang-bang)*

Exemple

```
mon_count <- function(dataset, ..., nom=nombre){
  variables <- quos(...) # une liste de quosure
  nom <- enquo(nom)
  dataset %>%
    group_by( !!! variables ) %>%
    summarise( !! quo_name(nom) := n() )
}
```

Exemple

```
mon_count <- function(dataset, ..., nom=nombre){
  variables <- quos(...) # une liste de quosure
  nom <- enquo(nom)
  dataset %>%
    group_by( !!! variables ) %>%
    summarise( !! quo_name(nom) := n() )
}
```

```
iris %>%
  mutate(couleur = sample(c("bleu", "rouge"), 150, replace = TRUE)) %>%
mon_count(Species, couleur)
```

```
#> # A tibble: 6 x 3
#> # Groups:   Species [?]
#>   Species    couleur nombre
#>   <fct>      <chr>    <int>
#> 1 setosa     bleu        28
#> 2 setosa     rouge       22
#> 3 versicolor bleu        25
#> 4 versicolor rouge       25
```

Merci !

Me trouver sur le net:

- vincent@thinkr.fr
- http://twitter.com/vincentguyader
- http://twitter.com/thinkr_fr

Mais aussi:

- https://rtask.thinkr.fr/
- https://thinkr.fr/