Refresher

Pratiques de la Recherche en Économie

Florentine Oliveira-Roux
4 Novembre 2025

Pour me contacter

Doctorante en Économie à PSE en 4ème année

Champs de recherche: économie de la famille, de l'éducation, du travail

Pour me contacter, si vous avez des questions ou envie/besoin de parler:

florentine.oliveira@psemail.eu

Campus Jourdan, Bureau R4-54

Objectifs du cours

- Se familiariser avec
  - les techniques **économétriques** de base
  - la **recherche** en **économie empirique**
- Apprendre le language de programmation `R`

$\Longrightarrow$ pour pouvoir réaliser votre **mémoire** !

Roadmap

Semestre 1

1. Séance 1 (aujourd'hui): Rappels de `R`
2. Séance 2 (18/11/2025): $\LaTeX$ et R Markdown
3. Séance 3 (02/12/2025): Régressions Linéaires et Causalité

Semestre 2

1. Séance 4 (TBC - 03/02/2026): Variables de Contrôle et Matching
2. Séance 5 (TBC - 17/02/2026): Méthode des Variables Instrumentales
3. Séance 6 (TBC - 03/03/2026): Méthode des Doubles-Différences (DiD)
4. Séance 7 (TBC - 17/03/2026): Regression Discontinuity Design (RDD)
5. Séance 8 (TBC - 31/03/2026): Q & A

Validation du cours

DM

Objectif: manipulation de données sur `R`, intuition, quelques régressions

À faire seul(e) ou à deux

À rendre pour le 4 Janvier 2026 à 23h59 maximum

Mémoire

Cette séance

1. La recherche en économie empirique

2. `R` : Rappels

2.1. Définition, usages, interface
2.2. Projet `R`
2.3. Importer des données
2.4. Manipulation des données avec `dplyr`
2.5. Visualisation des données avec `ggplot`
2.6. Maps

1. La recherche en économie empirique

Qu'est-ce que la recherche en économie empirique?

- Répondre à des **questions de recherche** pour apprendre sur les comportements humains, l'efficacité des poliques publiques, ...
  - Quel est l'effet des bourses de scolarité **sur** la réussite scolaire?
  - Quel est l'effet d'un allongement de la durée du congé parental **sur** la participation au marché du travail des mères?
  - Quelle est l'ampleur de la discrimination dans le processus de recrutement?
  - Quel est l'effet d'un assouplissement des conditions d'éligibilité à l'assurance chômage **sur** l'emploi?
  - Quel est l'effet de la pollution atmosphérique **sur** la productivité?
  - Quel est le rôle des médias **sur** le comportement de vote?
  - Quel est l'effet de la densité de population **sur** les salaires?

Qu'est-ce que la recherche en économie empirique?

- Répondre à des **questions de recherche** pour apprendre sur les comportements humains, l'efficacité des poliques publiques, ...
    - Grande diversité des champs de recherche: éducation, travail, famille, environnement, macroéconomie, politique, migration, genre, urban, crime, économie historique, ...
- ... en utilisant des techniques statistiques rigoureuses (= **économétrie**) ...
- ... une stratégie/un cadre qui nous permet d'identifier un **effet causal**...
- ... et des données!
- `R` est un logiciel qui permet de réaliser ces analyses descriptives et empiriques

2. R: rappels

2.1. Définition, usage, interface

Définition

- D'après le site internet de `R` : *R is a free software environment for statistical computing and graphics.*
  - un logiciel (interface R studio)
  - un language de programmation
- `R` est **gratuit** et en **open source**
  - donc très utilisé dans les milieux académique et institutionnel
- Logiciel très **polyvalent**
  - statistiques decriptives, analyses économétriques, analyse de données spaciales, ML, Rmarkdown
- Compétence valorisée et de plus en plus recherchée (public & privé)

Popularité de R[1]

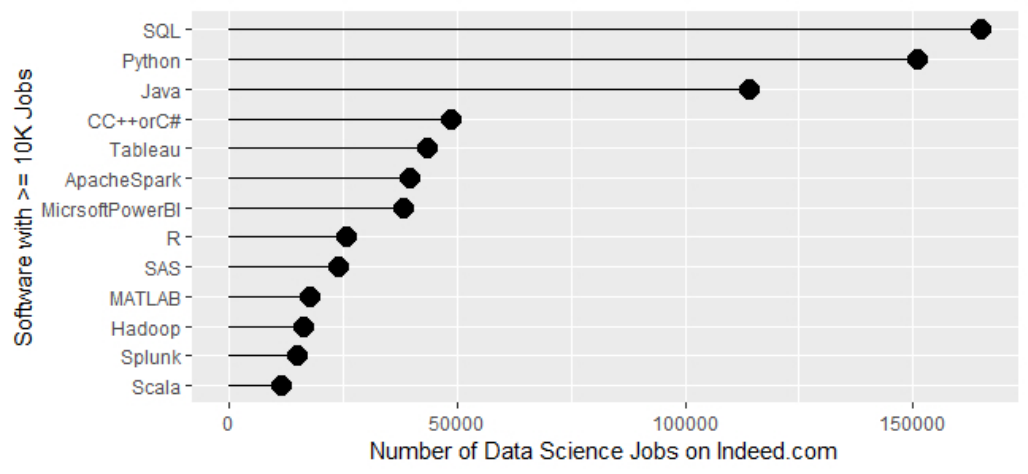

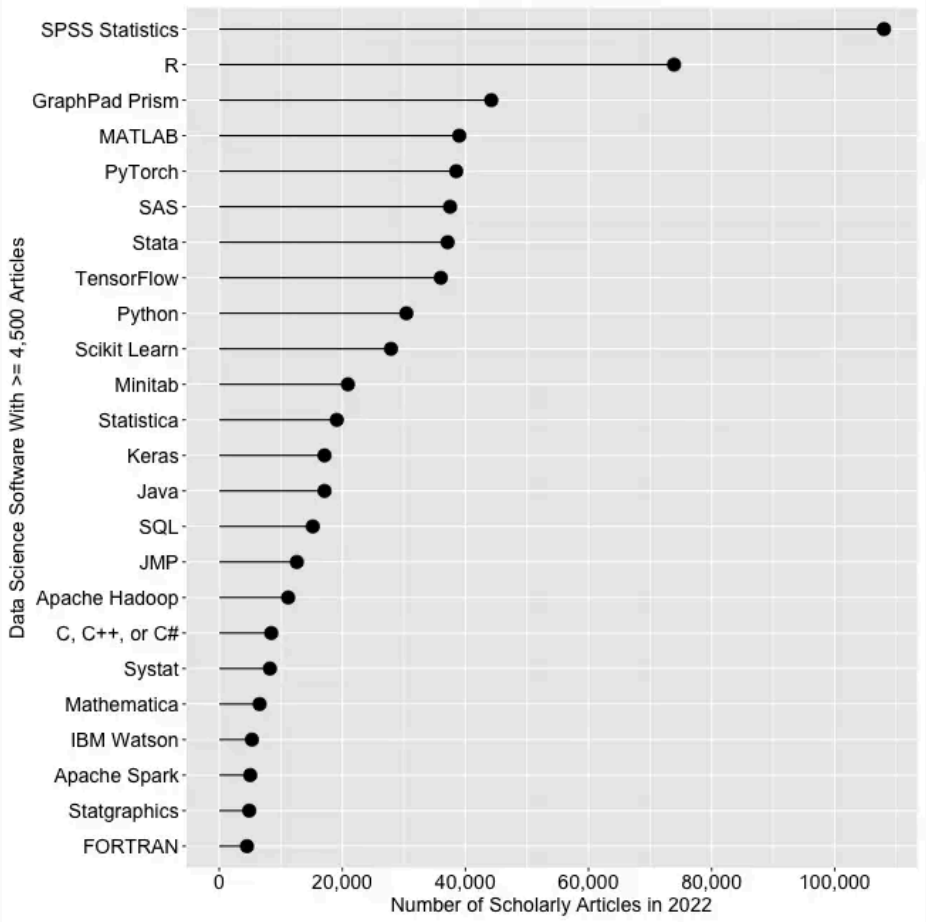

[1]: The Popularity of Data Science Software

Interface

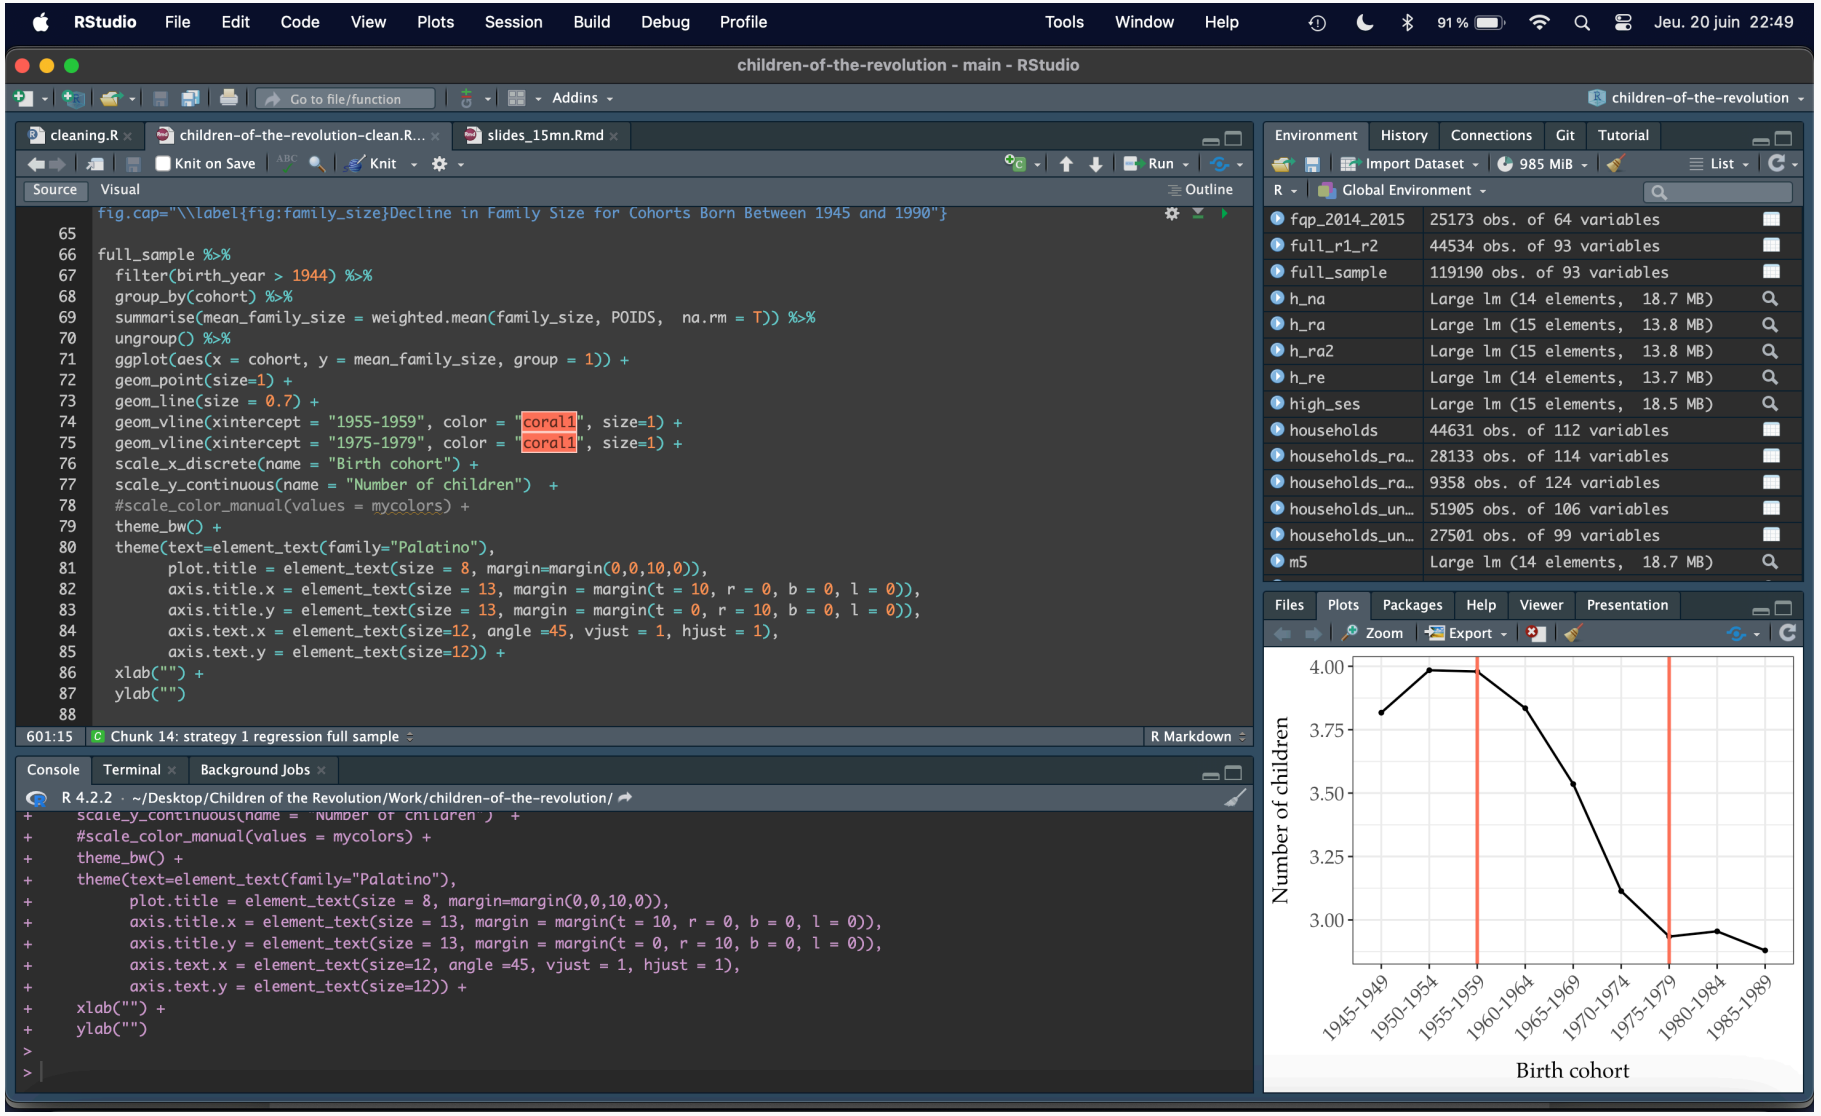
RStudio File Edit Code View Plots Session Build Debug Profile Tools Window Help 91 % Jeu. 20 juin 22:49
children-of-the-revolution - main - RStudio
Go to file/function
Addins
children-of-the-revolution
cleaning.R
children-of-the-revolution-clean.R...
slides_15mn.Rmd
Knit on Save
Knit
Run
Source
Visual
Outline
fig.cap="\\label{fig:family_size}Decline in Family Size for Cohorts Born Between 1945 and 1990"}
full_sample %>%
filter(birth_year > 1944) %>%
group_by(cohort) %>%
summarise(mean_family_size = weighted.mean(family_size, POIDS, na.rm = T)) %>%
ungroup() %>%
ggplot(aes(x = cohort, y = mean_family_size, group = 1)) +
geom_point(size=1) +
geom_line(size = 0.7) +
geom_vline(xintercept = "1955-1959", color = "coral1", size=1) +
geom_vline(xintercept = "1975-1979", color = "coral1", size=1) +
scale_x_discrete(name = "Birth cohort") +
scale_y_continuous(name = "Number of children") +
#scale_color_manual(values = mycolors) +
theme_bw() +
theme(text=element_text(family="Palatino"),
plot.title = element_text(size = 8, margin=margin(0,0,10,0)),
axis.title.x = element_text(size = 13, margin = margin(t = 10, r = 0, b = 0, l = 0)),
axis.title.y = element_text(size = 13, margin = margin(t = 0, r = 10, b = 0, l = 0)),
axis.text.x = element_text(size=12, angle =45, vjust = 1, hjust = 1),
axis.text.y = element_text(size=12)) +
xlab("") +
ylab("")
601:15
Chunk 14: strategy 1 regression full sample
R Markdown
Console
Terminal
Background Jobs
R 4.2.2 · ~/Desktop/Children of the Revolution/Work/children-of-the-revolution/
Environment
History
Connections
Git
Tutorial
Import Dataset
985 MiB
List
R
Global Environment
fqp_2014_2015 25173 obs. of 64 variables
full_r1_r2 44534 obs. of 93 variables
full_sample 119190 obs. of 93 variables
h_na Large lm (14 elements, 18.7 MB)
h_ra Large lm (15 elements, 13.8 MB)
h_ra2 Large lm (15 elements, 13.8 MB)
h_re Large lm (14 elements, 13.7 MB)
high_ses Large lm (15 elements, 18.5 MB)
households 44631 obs. of 112 variables
households_ra... 28133 obs. of 114 variables
households_ra... 9358 obs. of 124 variables
households_un... 51905 obs. of 106 variables
households_un... 27501 obs. of 99 variables
m5 Large lm (14 elements, 18.7 MB)
Files
Plots
Packages
Help
Viewer
Presentation
Zoom
Export
Number of children
4.00
3.75
3.50
3.25
3.00
1945-1949
1950-1954
1955-1959
1960-1964
1965-1969
1970-1974
1975-1979
1980-1984
1985-1989
Birth cohort

2.2. Projet `R`

Projet `R`

Les projets `R` permettent une meilleure organisation de votre travail.

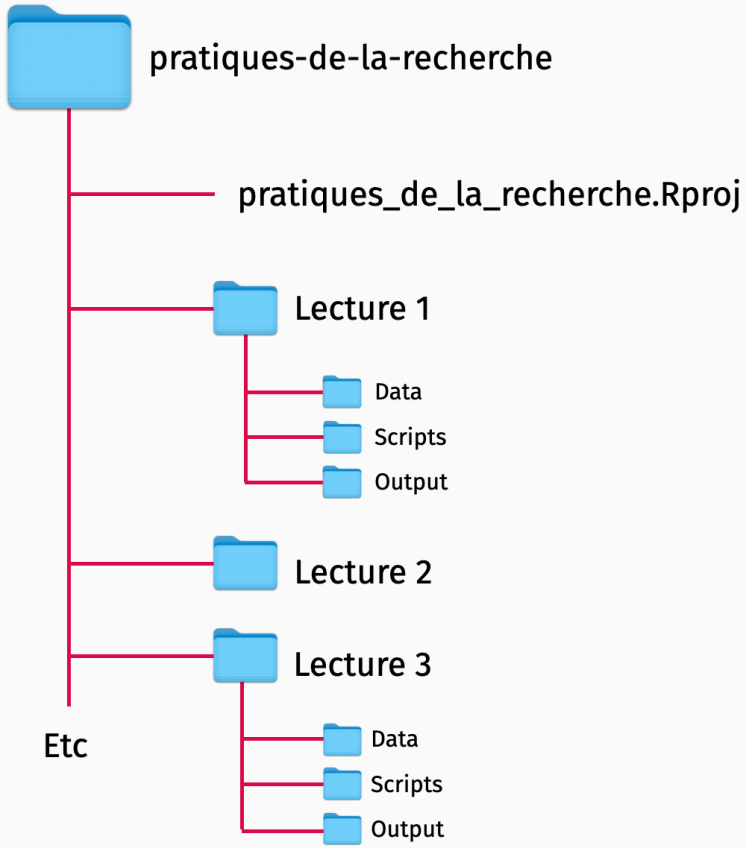

Création d'un projet `R` :

- Dans R-Studio
  - Fichier $\longrightarrow$ Nouveau projet

Application: créer votre projet R

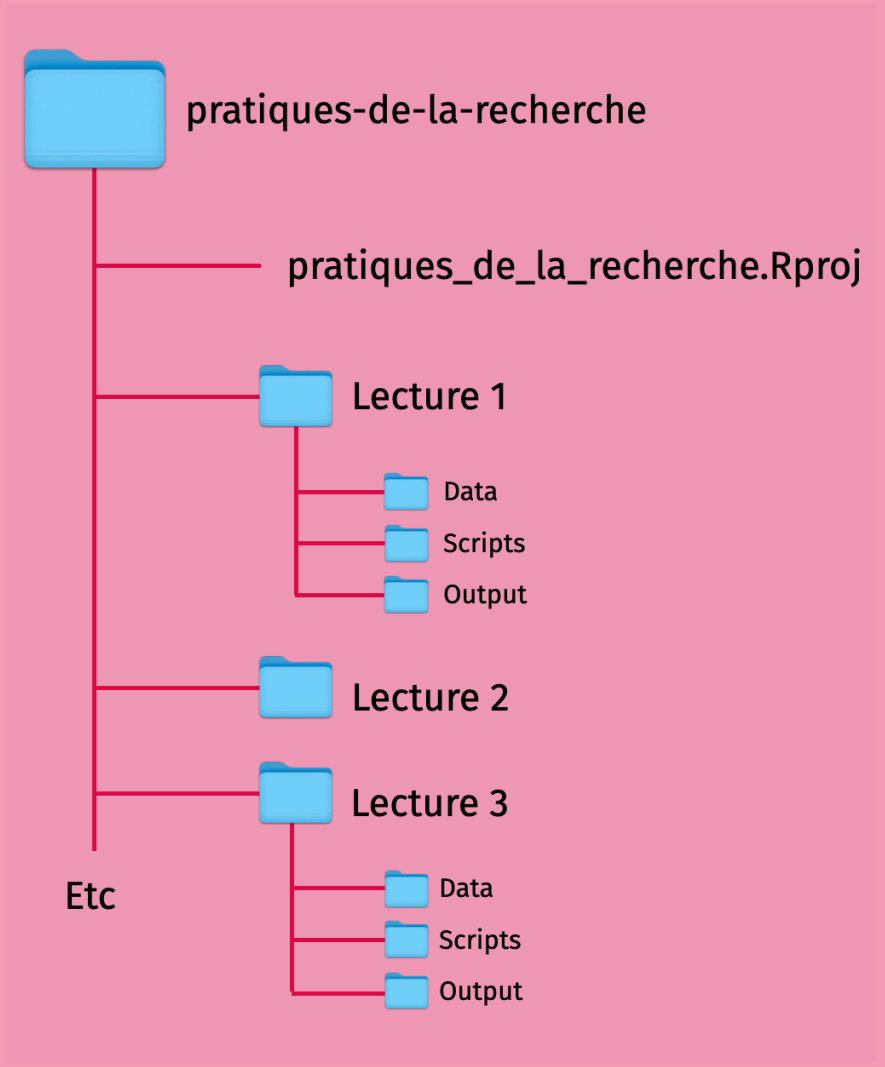

- Créer un projet R pour le TD en respectant cette structure
- Créer un nouveau script R dans le dossier Lecture 1/scripts, appelé lecture_1

2.3. Importer des données

Importer des données au format externes

Format .csv:

- `read.csv()` ou `read.cvs2()` avec l'argument `sep = ';'`

Formats .dta (stata), .sas7bdat (sas): package `haven` (nb: `haven` est inclus dans `tidyverse`)

- `.dta` : `read_dta()`
- `.sas7dbat` : `read_sas()`

Format .xls ou .xlsx (Excel): package `readxl`

- `read_excel()`

Importer des données R

Format .rds: format de données le moins lourd et optimal pour travailler sur R, surtout quand les bases de données sont très volumineuses

- `readRDS()`

Conseil: à la fin du script de cleaning, enregistrer le ou les data.frames nettoyés en format `.RDS` avec la fonction `saveRDS()` et importer ces données nettoyées dans le script sur lequel vous ferez toutes vos analyses.

2.4. Manipulation des données avec `dplyr`

Package `dplyr`

Principal package pour la manipulation de données : `dplyr`

$$\text{data.frame} \underbrace{\%>\%}_{\text{pipe}} \text{function(your action)}$$

Principales fonctions

- `mutate()` : créer ou modifier des variables
- `summarise()` : résume les données par des statistiques descriptives
- `filter()` : conserve ou supprime les lignes
- `group_by()` : permet de grouper des observations entre elles
- `select()` : conserve ou supprime des colonnes
- `arrange()` : ordonne les observations par rapport aux valeurs d'une colonne

Opérateurs

Opérateur arithmétiques	Description
`+` / `-`	Addition / Soustraction
`*` / `/`	Multiplication / Division
`^`	Exposant

Opérateur logiques	Description
`<` / `>`	Strictement inférieur / supérieur à
`<=` / `>=`	Supérieur / inférieur ou égal à
`==`	Égal à
`!=`	Différent de
`x %in% c(1,6)`	x dans $\{1, 6\}$
`x & y`	x *et* y
`x | y`	x *ou* y

Application : Titanic

Ce jeu de données fournit des informations sur le sort des passagers du paquebot « Titanic », résumées en fonction du statut économique (class), du sexe, de l'âge et de la survie.

```
titanic = as.data.frame(Titanic)

head(titanic)
```

```
##   Class    Sex   Age Survived Freq
## 1   1st   Male Child       No    0
## 2   2nd   Male Child       No    0
## 3   3rd   Male Child       No   35
## 4  Crew   Male Child       No    0
## 5   1st Female Child       No    0
## 6   2nd Female Child       No    0
```

Application : Titanic

1) Calculer le taux de survie par classe, par sexe, et par âge

2) Créer une variable `passenger` qui vaut 1 si l'individu n'est pas un membre d'équipage (*crew*), 0 si c'est un membre d'équipage

3) Créer une table qui résume, pour les adultes uniquement, le taux de survie par Classe x Sexe et ordonner par ordre décroissant

Solution : Titanic

1) Calculer le taux de survie par classe, par sexe, et par âge

```
titanic %>%
  group_by(Class) %>%
  summarise(tx_survie = sum(Freq[Survived == "Yes"])/sum(Freq)) %>%
  ungroup()
```

```
## # A tibble: 4 × 2
##   Class tx_survie
##   <fct>     <dbl>
## 1 1st       0.625
## 2 2nd       0.414
## 3 3rd       0.252
## 4 Crew      0.240
```

Solution : Titanic

1) Calculer le taux de survie par classe, par sexe, et par âge

```
titanic %>%
  group_by(Class) %>%
  summarise(tx_survie = sum(Freq[Survived == "Yes"])/sum(Freq)) %>%
  ungroup()
```

```
## # A tibble: 4 × 2
##   Class tx_survie
##   <fct>     <dbl>
## 1 1st       0.625
## 2 2nd       0.414
## 3 3rd       0.252
## 4 Crew      0.240
```

Solution : Titanic

1) Calculer le taux de survie par classe, par sexe, et par âge

```
titanic %>%
  group_by(Sex) %>%
  summarise(tx_survie = sum(Freq[Survived == "Yes"])/sum(Freq)) %>%
  ungroup()
```

```
## # A tibble: 2 × 2
##   Sex    tx_survie
##   <fct>      <dbl>
## 1 Male       0.212
## 2 Female     0.732
```

Solution : Titanic

1) Calculer le taux de survie par classe, par sexe, et par âge

```
titanic %>%
  group_by(Age) %>%
  summarise(tx_survie = sum(Freq[Survived == "Yes"])/sum(Freq)) %>%
  ungroup()
```

```
## # A tibble: 2 × 2
##   Age   tx_survie
##   <fct>     <dbl>
## 1 Child     0.523
## 2 Adult     0.313
```

Solution : Titanic

2) Créer une variable `passenger` qui vaut 1 si l'individu n'est pas un membre d'équipage (*crew*), 0 si c'est un membre d'équipage

```
# Solution 1
titanic %>%
  mutate(passenger = ifelse(Class ≠ "Crew", 1, 0))

# Solution 2
titanic %>%
  mutate(passenger = case_when(Class ≠ "Crew" ~ 1,
                               Class == "Crew" ~ 0))
```

Conseil: utiliser `case_when` quand il y a plus d'une condition

Solution : Titanic

3) Créer une table qui résume, pour les adultes uniquement, le taux de survie par Classe x Sexe et ordonner par ordre décroissant

```
titanic %>%
  filter(Age == "Adult") %>%
  group_by(Class, Sex) %>%
  summarise(tx_survie = sum(Freq[Survived == "Yes"]) / sum(Freq)) %>%
  arrange(desc(tx_survie))
```

Solution : Titanic

3) Créer une table qui résume, **pour les adultes uniquement**, le taux de survie par Classe x Sexe et ordonner par ordre décroissant

```
titanic %>%
  filter(Age == "Adult") %>%
  group_by(Class, Sex) %>%
  summarise(tx_survie = sum(Freq[Survived == "Yes"]) / sum(Freq)) %>%
  arrange(desc(tx_survie))
```

Solution : Titanic

3) Créer une table qui résume, pour les adultes uniquement, le taux de survie par **Classe x Sexe** et ordonner par ordre décroissant

```
titanic %>%
  filter(Age == "Adult") %>%
  group_by(Class, Sex) %>%
  summarise(tx_survie = sum(Freq[Survived == "Yes"]) / sum(Freq)) %>%
  arrange(desc(tx_survie))
```

Solution : Titanic

3) Créer une table qui résume, pour les adultes uniquement, le **taux de survie** par Classe x Sexe et ordonner par ordre décroissant

```
titanic %>%
  filter(Age == "Adult") %>%
  group_by(Class, Sex) %>%
  summarise(tx_survie = sum(Freq[Survived == "Yes"]) / sum(Freq)) %>%
  arrange(desc(tx_survie))
```

Solution : Titanic

3) Créer une table qui résume, pour les adultes uniquement, le taux de survie par Classe x Sexe et **ordonner par ordre décroissant**

```
titanic %>%
  filter(Age == "Adult") %>%
  group_by(Class, Sex) %>%
  summarise(tx_survie = sum(Freq[Survived == "Yes"]) / sum(Freq)) %>%
  arrange(desc(tx_survie))
```

```
## # A tibble: 8 × 3
## # Groups:   Class [4]
##   Class Sex    tx_survie
##   <fct> <fct>      <dbl>
## 1 1st   Female    0.972
## 2 Crew  Female    0.870
## 3 2nd   Female    0.860
## 4 3rd   Female    0.461
## 5 1st   Male      0.326
## 6 Crew  Male      0.223
## 7 3rd   Male      0.162
## 8 2nd   Male      0.0833
```

Jointures

a

x1	x2
A	1
B	2
C	3

+

b

x1	x3
A	T
B	F
D	T

= ?

- Très souvent, les données nécessaires à l'analyse sont issues de plusieurs sources
- Joindre deux tables de données peut permettre d'ajouter
  - des variables supplémentaires
  - des observations supplémentaires
- L'ajout de variables peut se faire sur la base:
  - de la position des observations dans les deux jeux de données: **binding joints**
  - relativement aux valeurs d'une ou plusieurs autres colonnes, les *clés*: **mutating joints**

Jointures

Binding joints

Binding Rows

a

x1	x2
A	1
B	2
C	3

+

b

x1	x3
A	T
B	F
D	T

=

x1	x2	X3
A	1	NA
B	2	NA
C	3	NA
A	NA	T
B	NA	F
D	NA	T

`bind_rows(a, b)`: dans une jointure de lignes, les colonnes sont associées à leur nom et toute colonne manquante est remplacée par NA.

Jointures

Binding joints

Binding Columns

a

x1	x2
A	1
B	2
C	3

+

b

x1	x3
A	T
B	F
D	T

=

x1	x2	x1	X3
A	1	A	T
B	2	B	F
C	3	D	T

`bind_cols(a, b)`: dans une jointure de colonnes, les lignes sont mises en correspondance en fonction de leur **position**

Jointures

Mutating joints

Left-joint

a

x1	x2
A	1
B	2
C	3

+

b

x1	x3
A	T
B	F
D	T

=

x1	x2	x3
A	1	T
B	2	F
C	3	NA

`left_join(a, b, by = "x1")`: pour chaque ligne de **a** on a ajouté les colonnes de **b** pour lesquelles la valeur de la *clé* **x1** est la même

Jointures

Mutating joints

Right-joint

a

x1	x2
A	1
B	2
C	3

+

b

x1	x3
A	T
B	F
D	T

=

x1	x3	x2
A	T	1
B	F	2
D	T	NA

`right_join(a, b, by = "x1")`: pour chaque ligne de **b** on a ajouté les colonnes de **a** pour lesquelles la valeur de la *clé* **x1** est la même

Jointures

Mutating joints

Inner-joint

a

x1	x2
A	1
B	2
C	3

+

b

x1	x3
A	T
B	F
D	T

=

x1	x2	x3
A	1	T
B	2	F

`inner_join(a, b, by = "x1")`: seules les lignes présentes à la fois dans **a** et **b** sont jointes

Jointures

Mutating joints

Full-joint

a

x1	x2
A	1
B	2
C	3

+

b

x1	x3
A	T
B	F
D	T

=

x1	x2	x3
A	1	T
B	2	F
C	3	NA
D	NA	T

`full_join(a, b, by = "x1")` : toutes les lignes de **a** et toutes les lignes de **b** sont jointes (avec des NA ajoutés si nécessaire) même si elles sont absentes de l'autre table

Différents formats de base de données

Formats wide et long

Pour **rassembler des colonnes** et passer en format **long**: `pivot_longer`

a

student	L1	L2
A	13.7	12.4
B	10.5	14.1
C	16.2	15.8

b

student	grade	mean
A	L1	13.7
B	L1	10.5
C	L1	16.2
A	L2	12.4
B	L2	14.1
C	L2	15.8

```
b = pivot_longer(a, cols = 2:3, names_to = "grade", values_to = "mean")
```

Différents formats de base de données

Formats wide et long

Pour **disperser des lignes** et obtenir un format **wide**: `pivot_wider`

a

student	grade	subject	mean
A	L1	statistics	12.3
A	L1	macro	10.9
A	L2	statistics	19
A	L2	macro	13.6
B	L1	statistics	11.2
B	L1	macro	17.1
B	L2	statistics	8.2
B	L2	macro	14.7
C	L1	statistics	12.8
C	L1	macro	13.5
C	L2	statistics	14.1
C	L2	macro	13.8

b

student	grade	statistics	macro
A	L1	12.3	10.9
A	L2	19	13.6
B	L1	11.2	17.1
B	L2	8.2	14.7
C	L1	12.8	13.5
C	L2	14.1	13.8

```
b = pivot_wider(a, names_from = subject, values_from = mean)
```

Application : Législatives 2024

Utilisation de 3 bases de données:

- résultats au premier tour: `resultats-definitifs-par-circonscription-t1.csv`
- résultats au second tour: `resultats-definitifs-par-circonscription-t2.csv`
- population par circonscription en 2019: `population_2019.csv`

Chaque observation = une circonscription

Les bases de *données des résultats aux élections sont en format wide*:

- chaque circonscription à un nombre fini de candidats (jusqu'à 19 candidats)
- les informations relatives aux différents candidats (nom, sexe, parti politique, etc) sont renseignées dans différentes variables
- les variables relatives au même candidat ont le même suffixe (eg Nom.candidat.1, Nuance.candidat.1, ...)

Application : Législatives 2024

🚨 Encodage du libellé des circonscriptions

```
head(resultats_t1[1:4,c(2,4)])
```

```
##   Libellé.département Libellé.circonscription.législative
## 1                 Ain                1ère circonscription
## 2                 Ain                2ème circonscription
## 3                 Ain                3ème circonscription
## 4                 Ain                4ème circonscription
```

```
head(pop_2019)[1:4,]
```

```
##   X. Circonscriptions Population.20191 ... hab ..
## 1  1         Ain, 1re                    122750
## 2  2          Ain, 2e                    137975
## 3  3          Ain, 3e                    146110
## 4  4          Ain, 4e                    128896
```

Variables Clés: `Libellé.département` qui comprend uniquement le nom du département, et `Libellé.circonscription` qui contient uniquement le numéro de la circonscription.

Application : Législatives 2024

🚨 **Encodage du libellé des circonscriptions**

```
resultats_t1 = resultats_t1 %>%
  mutate(Libellé.circonscription.législative = gsub("\\D", "", Libellé.circonscription.législative))

unique(resultats_t1$Libellé.circonscription.législative)
```

```
##  [1] "1"  "2"  "3"  "4"  "5"  "6"  "7"  "8"  "9"  "10" "11" "12" "13" "14" "15"
## [16] "16" "17" "18" "19" "20" "21"
```

$$\underbrace{\text{gsub}}_{\text{remplace}}\Big(\underbrace{\text{"\textbackslash\textbackslash D"}}_{\substack{\text{tout ce qui n'est}\\\text{pas numérique}}},\underbrace{\text{""}}_{\substack{\text{par une chaîne}\\\text{de caractères vide}}},\underbrace{\text{Libellé.circonscription.législative}}_{\substack{\text{dans la variable}\\\text{Libellé.circonscription.législative}}}\Big)$$

Application : Législatives 2024

🚨 **Encodage du libellé des circonscriptions**

```
pop_2019 = pop_2019 %>%
  separate(Circonscriptions, into = c("Libellé.département", "Libellé.circonscription.législative"), sep = ", ") %>%
  mutate(Libellé.circonscription.législative = gsub("\\D", "", Libellé.circonscription.législative))

unique(pop_2019$Libellé.circonscription.législative)
```

```
##  [1] "1"  "2"  "3"  "4"  "5"  "6"  "7"  "8"  "9"  "10" "11" "12" "13" "14" "15"
## [16] "16" "17" "18" "19" "20" "21"
```

$$\underbrace{\text{separate}}_{\text{sépare}}(\underbrace{\text{"Circonscriptions"}}_{\substack{\text{les caractères de la}\\\text{variable Circonscriptions}}}, \quad \underbrace{\text{into} = \text{c("A", "B")}}_{\substack{\text{en deux chaînes de caractères}\\\text{qui définissent ces deux variables}}} \quad , \quad \underbrace{\text{sep} = \text{", "}}_{\substack{\text{la séparation étant}\\\text{faite à l'endroit de}\\\text{la virgule}}} \quad)$$

Application : Législatives 2024

1) Importer les données (nommer les dataframes `resultats_t1`, `resultats_t2` et `pop_2019`)

2) Effectuer sur chaque jeu de données les opérations nécessaires pour harmoniser l'encodage du libellé de circonscription

- **pop-19**: `separate(Circonscriptions, into = c("Libellé.département", "Libellé.circonscription.législative"), sep = ", ")`
- **resultats_t1** et **resultats_t2** et **pop_2019**: `gsub("\\D", "", Libellé.circonscription.législative)`

3) Reformatter `resultats_t1` et `resultats_t2` en format long (chaque observation = un candidat)

4) Ajouter une variable `tour` qui vaut 1 dans `resultats_t1` et 2 dans `resultats_t2`

5) Ajouter les observations de `resultats_t2` à `resultats_t1` et stocker le tout dans `resultats`

6) Ne conserver que les observations des candidats élus

7) Joindre `pop_2019` à `resultats` et renommer `Population.20191...hab..` en `pop`

Solution

1) Importer les données

```
resultats_t1 = read.csv("data/resultats-definitifs-par-circonscription-t1.csv", sep = ";", na.strings=c("","NA"))
resultats_t2 = read.csv("data/resultats-definitifs-par-circonscription-t2.csv", sep = ";", na.strings=c("","NA"))
pop_2019 = read.csv("data/population_2019.csv", sep = ";")
```

2) Effectuer sur chaque jeu de données les opérations nécessaires pour harmoniser l'encodage du libellé de circonscription

```
resultats_t1 = resultats_t1 %>%
  mutate(Libellé.circonscription.législative = gsub("\\D", "", Libellé.circonscription.législative))

resultats_t2 = resultats_t2 %>%
  mutate(Libellé.circonscription.législative = gsub("\\D", "", Libellé.circonscription.législative))

pop_2019 = pop_2019 %>%
  separate(Circonscriptions, into = c("Libellé.département", "Libellé.circonscription.législative"), sep = ", ") %>%
  mutate(Libellé.circonscription.législative = gsub("\\D", "", Libellé.circonscription.législative))
```

Solution

3) Reformatter `resultats_t1` et `resultats_t2` en format long

4) Ajouter une variable `tour` qui vaut 1 dans `resultats_t1` et 2 dans `resultats_t2`

```
resultats_t1_long = resultats_t1 %>%
  pivot_longer(
    cols = matches(".*\\.[1-9]$|.*\\.[1][0-9]$"),
    names_to = c(".value", "candidate_number"),
    names_pattern = "(.*)\\.(\\d+)"
  ) %>%
  mutate(tour = 1)
```

Explication:

- `cols = matches(".*\\.[1-9]$|.*\\.[1][0-9]$")`: Sélectionne les colonnes dont le nom termine par un point suivi d'un nombre de 1 à 19

Solution

3) Reformatter `resultats_t1` et `resultats_t2` en format long

4) Ajouter une variable `tour` qui vaut 1 dans `resultats_t1` et 2 dans `resultats_t2`

```
resultats_t1_long = resultats_t1 %>%
  pivot_longer(
    cols = matches(".*\\.[1-9]$|.*\\.[1][0-9]$"),
    names_to = c(".value", "candidate_number"),
    names_pattern = "(.*)\\.(\\d+)"
  ) %>%
  mutate(tour = 1)
```

Explications:

- `names_to = c(".value", "candidate_number")` : définie le **nom** des nouvelles variables
  - `.value` crée de nouvelles variables dont le nom correspond à ce qui précède le point pour chaque variable ayant un suffixe numérique
  - `candidate_number` crée une nouvelle colonne qui contient les suffixes numériques (1 à 19) indiquant le numéro du candidat

Solution

3) Reformatter `resultats_t1` et `resultats_t2` en format long

4) Ajouter une variable `tour` qui vaut 1 dans `resultats_t1` et 2 dans `resultats_t2`

```
resultats_t1_long = resultats_t1 %>%
  pivot_longer(
    cols = matches(".*\\.[1-9]$|.*\\.[1][0-9]$"),
    names_to = c(".value", "candidate_number"),
    names_pattern = "(.*)\\.(\\d+)"
  ) %>%
  mutate(tour = 1)
```

Explications:

- `names_pattern = "(.*)\\.(\\d+)"` : utilise une expression régulière pour **séparer** les noms de colonnes en deux parties:
  - `(.*)` capture tout ce qui précède le point et l'assigne à `.value`
  - `(\\d+)` capture les nombres après le point et les assigne à `candidate_number`

Solution

3) Reformatter `resultats_t1` et `resultats_t2` en format long

4) Ajouter une variable `tour` qui vaut 1 dans `resultats_t1` et 2 dans `resultats_t2`

On reproduit les mêmes opérations sur `resultats_t2` (sauf que cette fois-ci il y a au maximum 4 candidats par circonscription)

```
resultats_t2_long = resultats_t2 %>%
  pivot_longer(
    cols = matches(".*\\.[1-4]$"),
    names_to = c(".value", "candidate_number"),
    names_pattern = "(.*)\\.(\\d+)"
  ) %>%
  mutate(tour = 2)
```

Solution

5) Ajouter les observations de `resultats_t2` à `resultats_t1` et stocker le tout dans `resultats`

6) Ne conserver que les observations des candidats élus

7) Joindre `pop_2019` à `resultats` et renommer `Population.20191...hab..` en `pop`

```
resultats = bind_rows(resultats_t1_long, resultats_t2_long) %>%
  filter(Elu == "élu") %>%
  left_join(pop_2019 %>% rename(pop = Population.20191...hab..), by = c("Libellé.département", "Libellé.circonscripti
```

2.5. Visualisation des données avec `ggplot2`

Package `ggplot2`

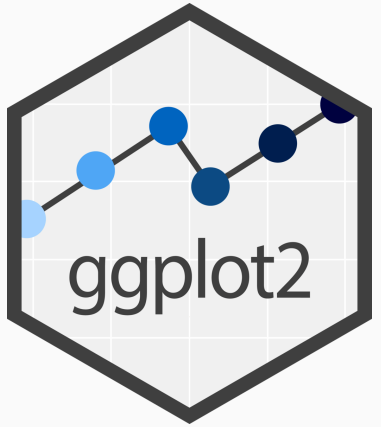

`ggplot2` est un package `R` qui permet de **visualiser des données** sous forme de graphiques

Afin de *chaîner* des opérations, c'est à dire d'**ajouter des couches au graphique,**

on utilise les `+` (l'équivalent de `%>%` avec `dplyr`)

Pour consturire n'importe quel graphique, il faut:

- une base de données
- lier les variables aux élements graphiques (axes, couleurs, tailles) via l'argument `aes()`
- définir un type de graphique (ligne, point, histogramme, densité, etc)

Structure de base

```
ggplot(data,
       aes(x = x, y = y)) +
  geom_point()
```

Principales fonctions

- `ggplot()` : Initialiser un graphique en spécifiant les données et les aesthetics
- `geom_` : Représente les types de graphiques:
  - `geom_point()` pour un nuage de points
  - `geom_line()` pour des lignes
  - `geom_bar()` pour un histogramme/barplot
  - `geom_density()` pour une densité
- `labs()` : Ajouter des titres et légendes
- `theme()` : Personnaliser l'apparence du graphique

Variable *discrète*

```
ggplot(resultats,
       aes(x = Nuance.candidat)) +
  geom_bar() +
  labs(
    title = "Nombre de sièges par parti",
    x = "Parti",
    y = "Nombre de sièges") +
  theme_minimal()
```

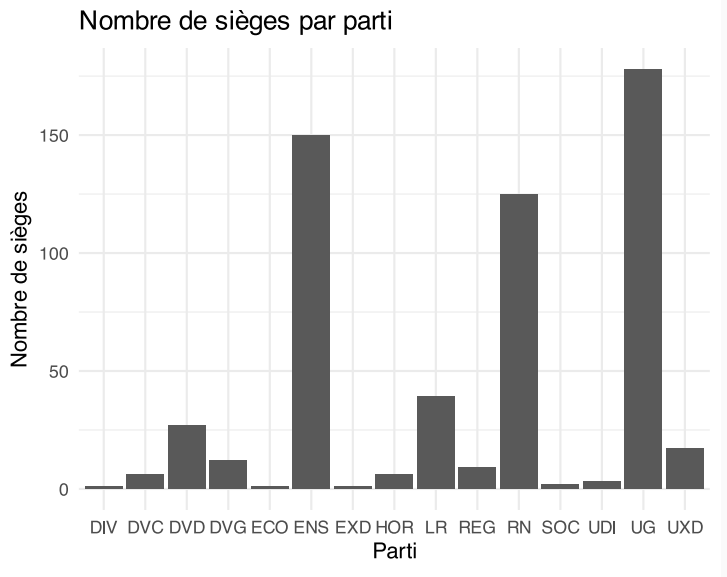

Variable *discrète*

```
resultats %>%
  count(Nuance.candidat) %>%
  mutate(percentage = n/sum(n)*100) %>%
  ggplot(aes(x = Nuance.candidat,
             y = percentage)) +
  geom_bar(stat = "identity") +
  labs(
    title = "Proportion de sièges par parti",
    x = "Parti",
    y = "Proportion de sièges") +
  theme_minimal()
```

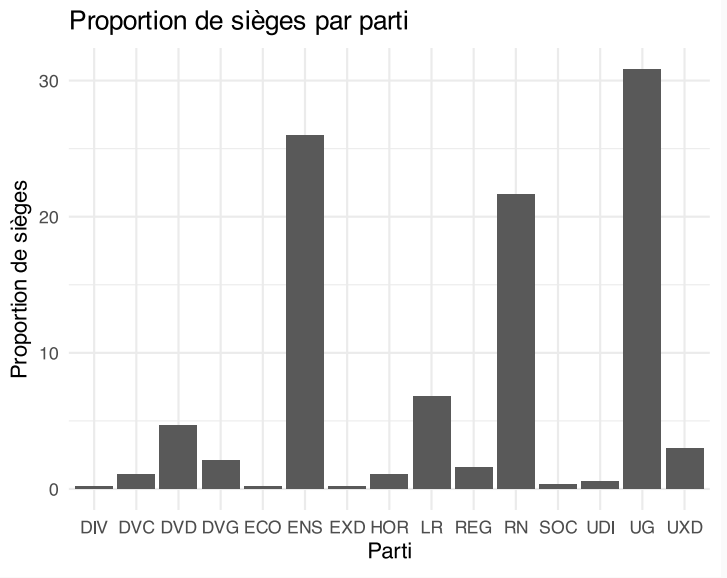

La fonction `count()` compte le nombre d'observation par groupe `Nuance.candidat` et stocke cette information dans une nouvelle variable, `n` (équivaut à `group_by(Nuance.candidat) %>% summarize(n = n())`)

Variable *discrète*

```
ggplot(resultats,
       aes(x = Nuance.candidat, fill = Sexe.candidat)) +
  geom_bar() +
  labs(
    title = "Nombre de sièges par parti",
    x = "Parti",
    y = "Nombre de sièges") +
   theme_minimal() +
   theme(legend.position="bottom")
```

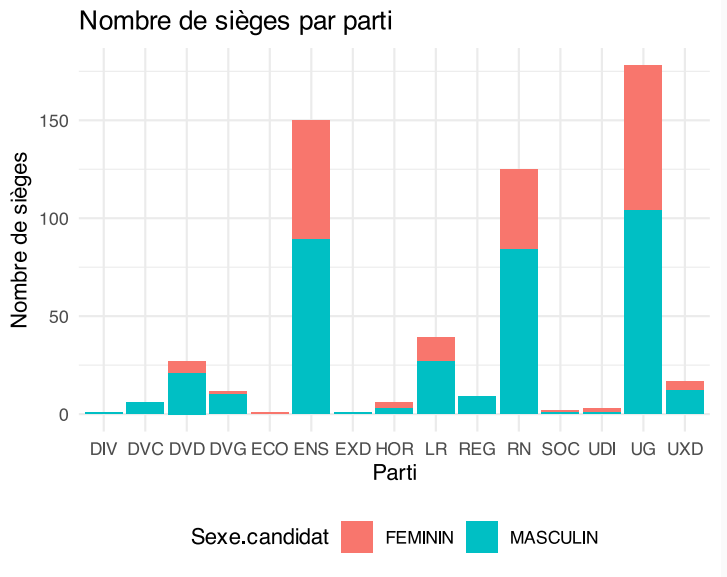

Variable *continue*

```
resultats %>%
    mutate(Blancs = as.numeric(Blancs)/100) %>%
    ggplot(aes(x = Blancs)) +
    geom_density() +
    labs(
        title = "Distribution des votes blancs",
        x = "Votes blancs (en centaines)",
        y = "Fréquence") +
    theme_minimal()
```

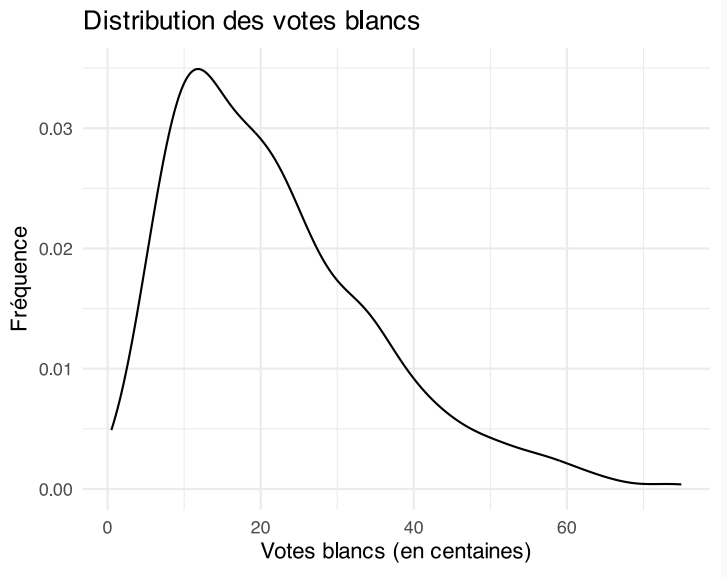

facet_wrap

```
resultats %>%
  group_by(Nuance.candidat) %>%
  count(Sexe.candidat) %>%
  mutate(percentage = n/sum(n)*100) %>%
  ggplot(aes(x = Sexe.candidat,
             y = percentage)) +
  geom_bar(stat = "identity") +
  labs(
    title = "Proportion de sièges par parti",
    x = "Parti",
    y = "Proportion de sièges") +
  facet_wrap( ~ Nuance.candidat) +
  theme_minimal()
```

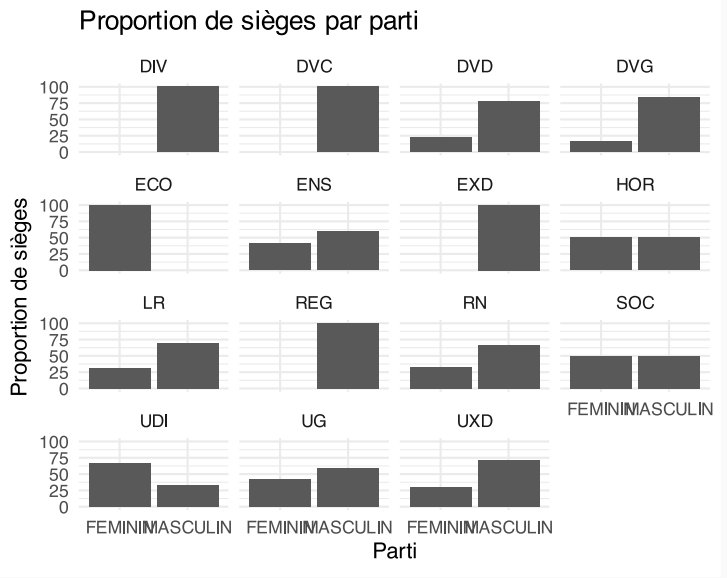

2.6. Visualisation des données spaciales

Format de cartes et données

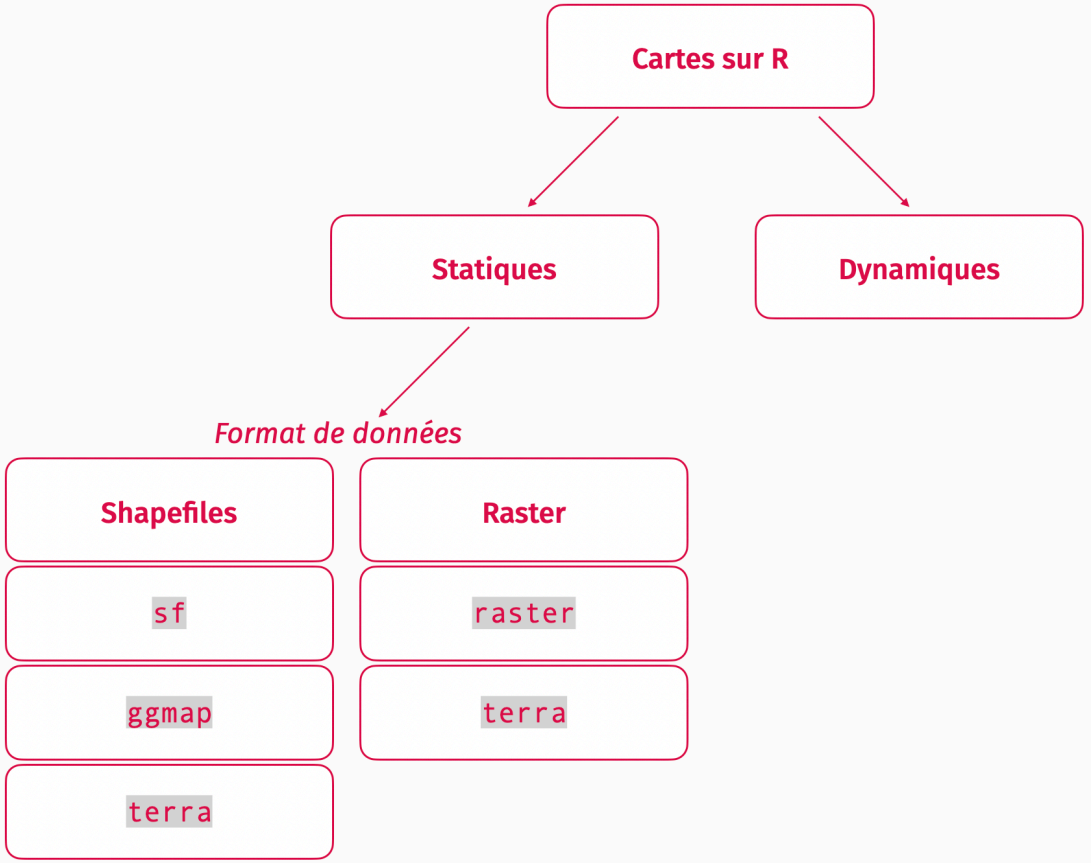

Très bonne référence: Géomatique sur R

Format de cartes et données

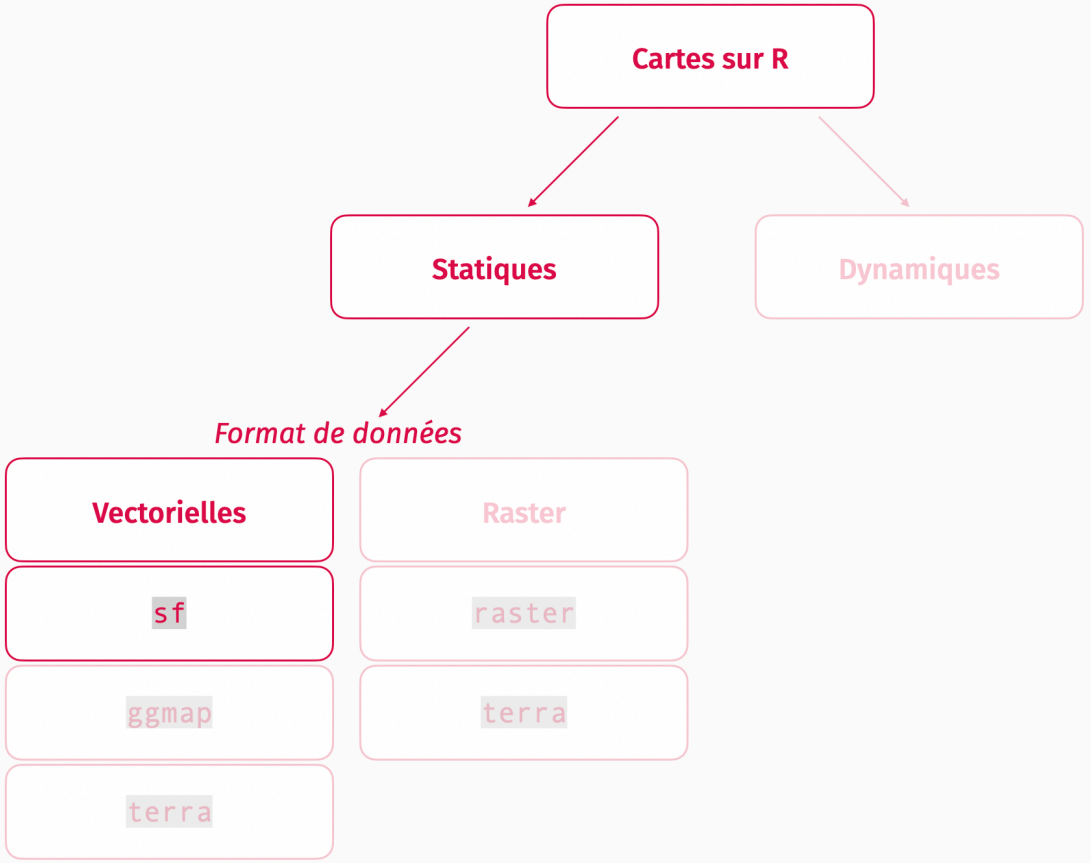

Très bonne référence: Géomatique sur R

Package `sf`

Shapefile: format de fichier géospatial utilisé pour représenter des entités géographiques

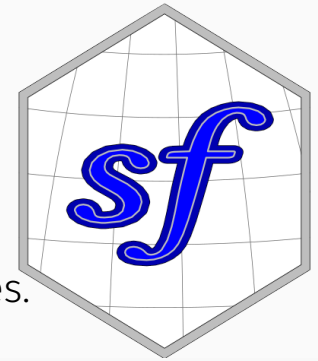

- contient des informations sur la forme (polygones, points, lignes) et des attributs.
- composé de plusieurs fichiers `.shp`, `.shx`, `.dbf`, tous nécessaires pour la réalisation de cartes

Une fois importés sur `R`, les objets `sf` sont des `data.frame` dont l'une des colonnes contient des géométries.

```
head(map[ , -c(5,6)],3)
```

```
## Simple feature collection with 3 features and 4 fields
## Geometry type: MULTIPOLYGON
## Dimension:     XY
## Bounding box:  xmin: -0.595231 ymin: 44.80615 xmax: 5.889757 ymax: 50.7899
## Geodetic CRS:  WGS 84
##      ID Code.département code_reg nom_dpt                       geometry
## 1 33004               33       75 GIRONDE MULTIPOLYGON (((-0.454946 4 ...
## 2 38001               38       84   ISERE MULTIPOLYGON (((5.805288 45 ...
## 3 59010               59       32    NORD MULTIPOLYGON (((3.058745 50 ...
```

Réaliser une carte en 3 étapes

1. Importer les données
    - Le jeu de données qui contient l'information à visualiser
    - Les fichiers `shapefiles` qui contiennent le fond de carte, etc, avec la fonction `st_read()`
    - 🚨 : on importe sur `R` uniquement le fichier `.shp`, mais tous les autres fichiers (`.shx`, `.dbf`, etc) téléchargés avec le *shapefile* doivent être localisés au même endroit que le `.shp`
2. Lier le jeu de données qui contient l'information à visualiser avec les données géographiques
    - Pour ajouter de l'information à un fond de carte, il est nécessaire de disposer d'une **variable (*key*) géographique commune entre les deux fichiers**
3. Représenter la carte avec la fonction `geom_sf()` sur le même principe que `geom_line()` par exemple avec `ggplot2`
    - Ici, l'esthétique du graphique (`aes`) comprend un nouvel argument, `geometry`, qui doit être égal à la variable contenant les données géographiques

Application: carte résultats législatives

Importer les données

1) Importer `france-circonscriptions-legislatives-2012.shp`, que vous stockerez dans `maps`

Cleaning

2) Renommer `code_dpt` en `Code.département` et `num_circ` en `Libellé.circonscription`

3) Modifier la variable `Code.département` : *si* le premier caractère est un `0`, `Code.département` prend la valeur du deuxième caracère. *Sinon* pas de modification

Joindre les bases de données

4) Ajouter les informations de `map` à `resultats` et stocker le tout dans `resultats_map`

Réaliser une carte

5) Réaliser la carte des résultats des éléctions législatives de 2024

NB: ne pas sélectionner les départements 971, 972, 973, 974, 975, 976, 986, 987, 988, ZX, ZZ qui correspondent aux DROM et qui ne sont pas sur ce fond de carte

Solution

Importer les données

1) Importer `france-circonscriptions-legislatives-2012.shp`, que vous stockerez dans `maps`

Cleaning

2) Renommer `code_dpt` en `Code.département` et `num_circ` en `Libellé.circonscription`

3) Modifier la variable `Code.département` : *si* le premier caractère est un `0`, `Code.département` prend la valeur du deuxième caracère. *Sinon* pas de modification

```
# Import data
map = st_read("data/france-circonscriptions-legislatives-2012.shp", quiet = TRUE) %>%
  rename(Code.département = code_dpt,
         Libellé.circonscription.législative = num_circ) %>%
  mutate(Code.département = ifelse(substr(Code.département, 1, 1) == "0", substr(Code.département, 2, 2), Code.départ
```

Solution

Importer les données

1) Importer `france-circonscriptions-legislatives-2012.shp`, que vous stockerez dans `maps`

Cleaning

2) Renommer `code_dpt` en `Code.département` et `num_circ` en `Libellé.circonscription`

3) Modifier la variable `Code.département` : *si* le premier caractère est un `0`, `Code.département` prend la valeur du deuxième caracère. *Sinon* pas de modification

```
# Import data
map = st_read("data/france-circonscriptions-legislatives-2012.shp", quiet = TRUE) %>%
  rename(Code.département = code_dpt,
         Libellé.circonscription.législative = num_circ) %>%
  mutate(Code.département = ifelse(substr(Code.département, 1, 1) == "0", substr(Code.département, 2, 2), Code.départ
```

Solution

Importer les données

1) Importer `france-circonscriptions-legislatives-2012.shp`, que vous stockerez dans `maps`

Cleaning

2) Renommer `code_dpt` en `Code.département` et `num_circ` en `Libellé.circonscription`

3) Modifier la variable `Code.département` : *si* le premier caractère est un `0`, `Code.département` prend la valeur du deuxième caracère. *Sinon* pas de modification

```
# Import data
map = st_read("data/france-circonscriptions-legislatives-2012.shp", quiet = TRUE) %>%
  rename(Code.département = code_dpt,
         Libellé.circonscription.législative = num_circ) %>%
  mutate(Code.département = ifelse(substr(Code.département, 1, 1) == "0", substr(Code.département, 2, 2), Code.départ
```

Solution

Joindre les bases de données

4) Ajouter les informations de `map` à `resultats` et stocker le tout dans `resultats_map`

```
# Merge geographic data and results data
resultats_map = resultats %>%
  left_join(map , by = c("Code.département", "Libellé.circonscription.législative"))
```

Solution

Réaliser une carte

5) Réaliser la carte des résultats des éléctions législatives de 2024

NB: ne pas sélectionner les départements 971, 972, 973, 974, 975, 976, 986, 987, 988, ZX, ZZ qui correspondent aux DROM et qui ne sont pas sur ce fond de carte

```
# Draw map
ggplot(resultats_map %>% filter(! (Code.département %in% c("971", "972", "973", "974", "975", "976", "986", "987", "9
  geom_sf(aes(fill = Nuance.candidat, geometry = geometry)) +
  theme_minimal() +
  scale_fill_manual(values = hcl.colors(14, "Purple-Yellow")) +
  labs(title = "Résultats des élections législatives par circonscription",
       fill = "Parti") +
  theme(legend.position = "bottom",
        axis.text = element_blank(),
        axis.ticks = element_blank(),
        panel.grid = element_blank()) +
  guides(fill = guide_legend(nrow = 1))
```

Solution

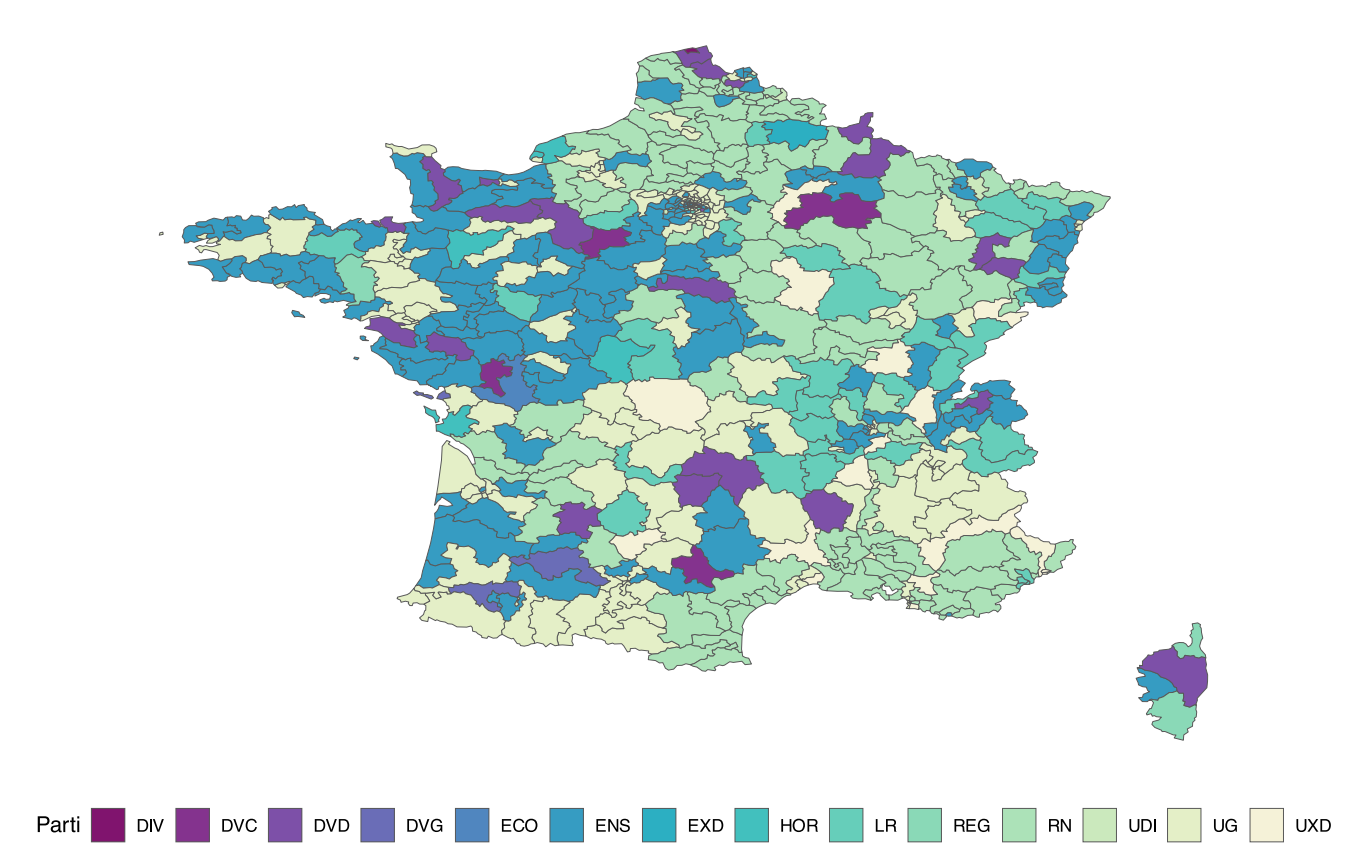

Miscellaneous

Vos 4 meilleurs amis

1. La **commande** `help(.)` ou `?.`

Vos 4 meilleurs amis

1. La **commande** `help(.)` ou `?.`
2. Les ***cheatsheets***
    - Exemple

Vos 4 meilleurs amis

1. La **commande** `help(.)` ou `?.`
2. Les ***cheatsheets***
    - Exemple
3. **Internet** (stackoverflow):
    - vous ne serez jamais la première personne à rencontrer les problèmes auxquels vous faites face
    - copier/coller le message d'erreur peut suffire, mais essayez de comprendre par vous même d'abord

Vos 4 meilleurs amis

1. La **commande** `help(.)` ou `?.`
2. Les ***cheatsheets***
   - Exemple
3. **Internet** (stackoverflow):
   - vous ne serez jamais la première personne à rencontrer les problèmes auxquels vous faites face
   - copier/coller le message d'erreur peut suffire, mais essayez de comprendre par vous même d'abord
4. **ChatGPT**: devient de plus en plus performant pour résoudre les problèmes de codes.
   - ⚠️ souvent les packages ne sont pas à jour, les fonctions proposées inventées

Vos 4 meilleurs amis

1. La **commande** `help(.)` ou `?.`
2. Les ***cheatsheets***
    - Exemple
3. **Internet** (stackoverflow):
    - vous ne serez jamais la première personne à rencontrer les problèmes auxquels vous faites face
    - copier/coller le message d'erreur peut suffire, mais essayez de comprendre par vous même d'abord
4. **ChatGPT**: devient de plus en plus performant pour résoudre les problèmes de codes.
    - ⚠️ souvent les packages ne sont pas à jour, les fonctions proposées inventées

🤝 Soyez autonomes: ne demander de l'aide à vos camarades (ou à moi) uniquement après avoir demandé à vos 4 meilleurs amis!

Bonnes pratiques

Organisation du travail

Un dossier pour chaque projet de recherche et différents sous-dossiers pour:

- Scripts
  - un scripts par tâche: cleaning, statistiques descriptives, anlayse empirique
- Data
  - `.rds`
- Figures
- (Admin)
  - par exemple les documents relatifs à l'accès à une base de données

Commenter son code pour soi...[1]

… et ses collègues[1]

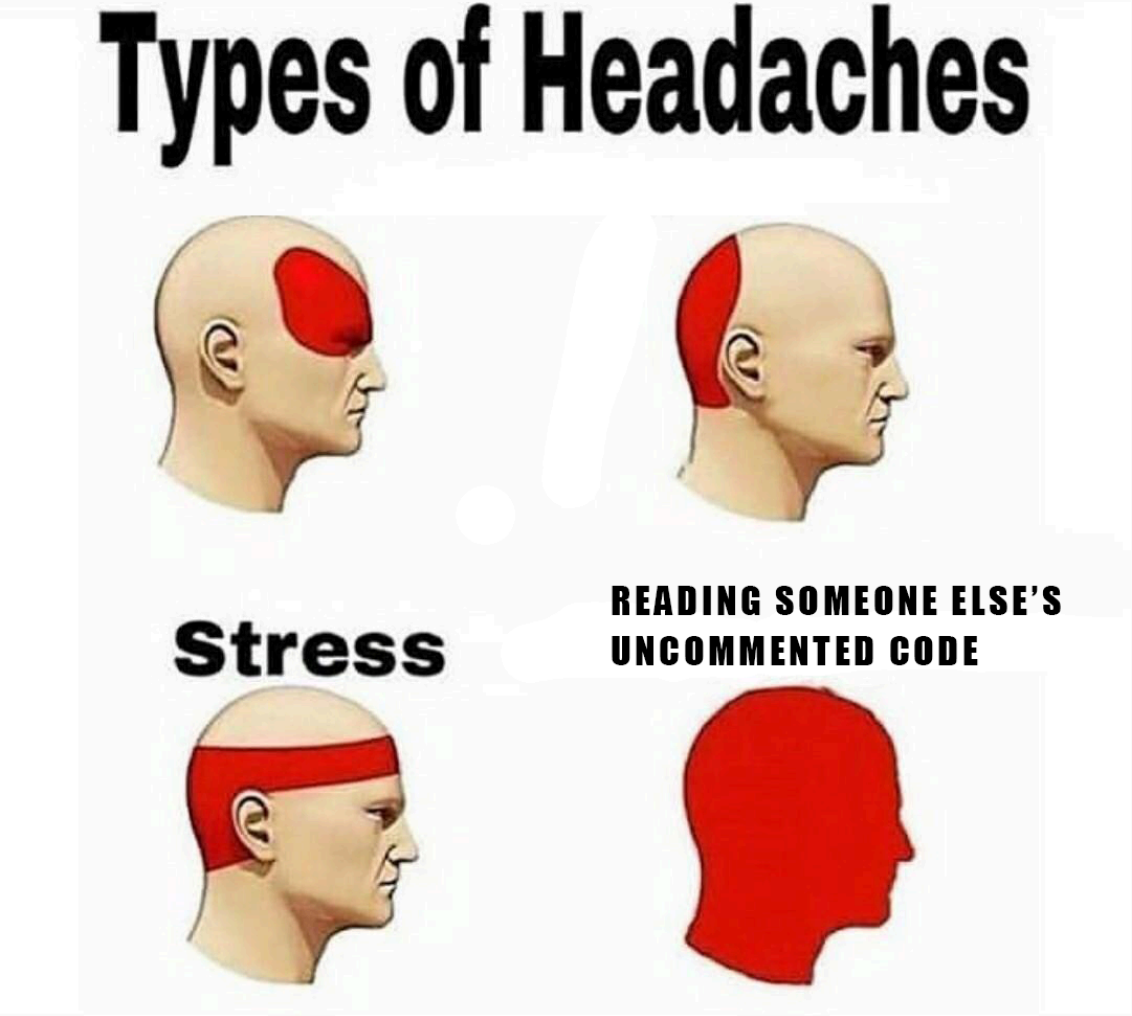

Essayer de ne pas s'énerver[1]

L'apprentissage de `R` est long et fastidieux, mais les rendements sont croissants!

[1]: R Memes For Statistical Fiends

References

Introduction à l'analyse d'enquêtes avec R et RStudio

Introduction to Econometrics & R Programming, Louis Sirugue

Econometrics, Florian Oswald

Causal inference: The Mixtape, Scott Cunningham

Géomatique sur R

Appendix

Cheatsheets

- R Studio Environment
- All cheatsheets

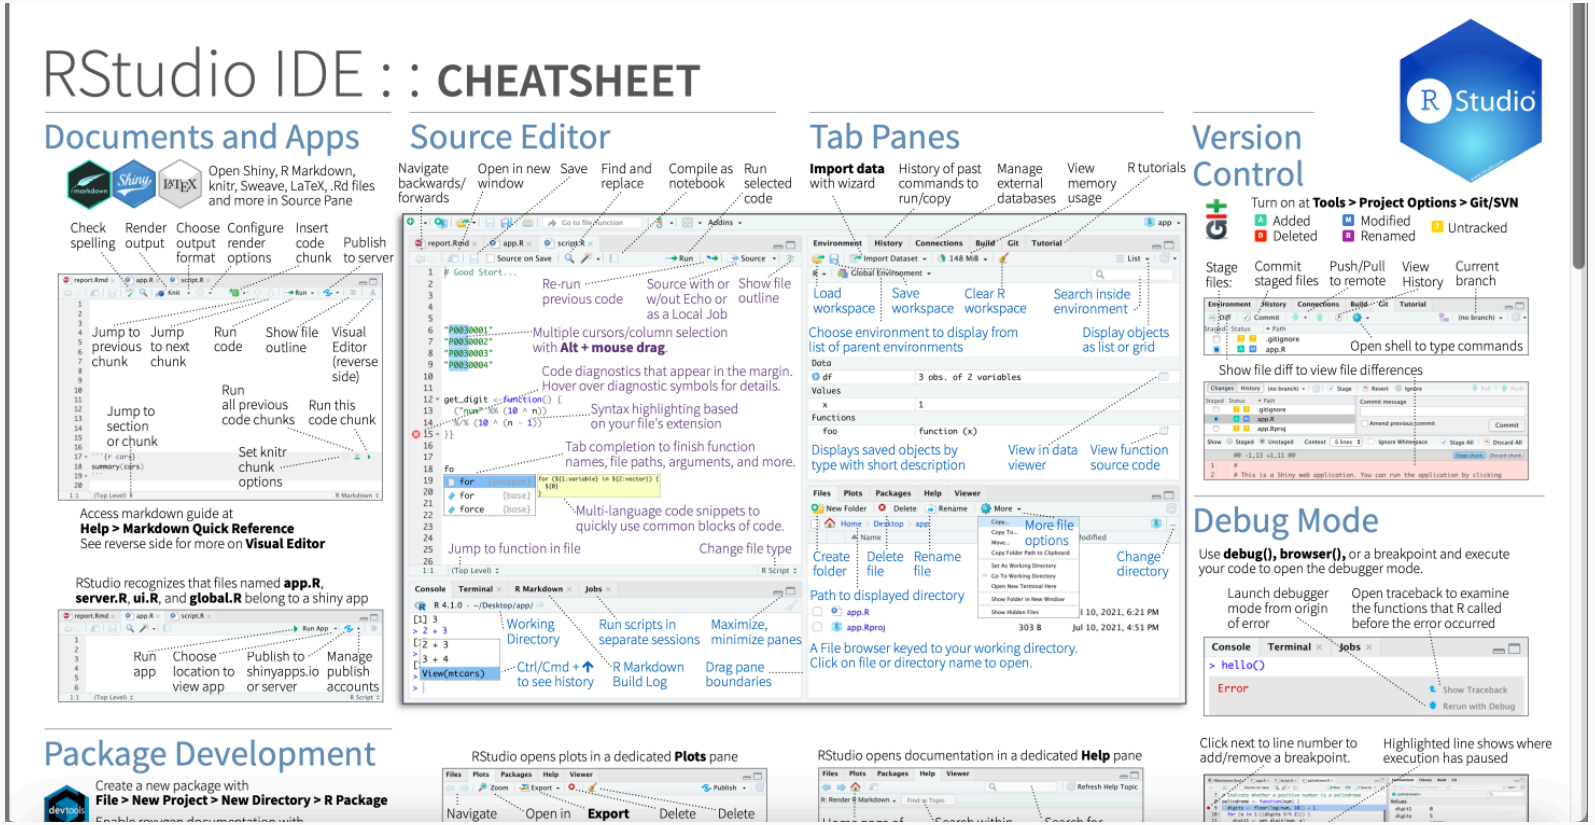
RStudio IDE : : CHEATSHEET
Documents and Apps
Open Shiny, R Markdown, knitr, Sweave, LaTeX, .Rd files and more in Source Pane
Check spelling
Render output
Choose output format
Configure render options
Insert code chunk
Publish to server
Jump to previous chunk
Jump to next chunk
Run code
Show file outline
Visual Editor (reverse side)
Jump to section or chunk
Run all previous code chunks
Run this code chunk
Set knitr chunk options
Access markdown guide at
Help > Markdown Quick Reference
See reverse side for more on Visual Editor
RStudio recognizes that files named app.R, server.R, ui.R, and global.R belong to a shiny app
Run app
Choose location to view app
Publish to shinyapps.io or server
Manage publish accounts
Source Editor
Navigate backwards/ forwards
Open in new window
Save
Find and replace
Compile as notebook
Run selected code
Re-run previous code
Source with or w/out Echo or as a Local Job
Show file outline
Multiple cursors/column selection with Alt + mouse drag.
Code diagnostics that appear in the margin. Hover over diagnostic symbols for details.
Syntax highlighting based on your file's extension
Tab completion to finish function names, file paths, arguments, and more.
Multi-language code snippets to quickly use common blocks of code.
Jump to function in file
Change file type
Working Directory
Run scripts in separate sessions
Maximize, minimize panes
Ctrl/Cmd + ↑ to see history
R Markdown Build Log
Drag pane boundaries
Tab Panes
Import data with wizard
History of past commands to run/copy
Manage external databases
View memory usage
R tutorials
Load workspace
Save workspace
Clear R workspace
Search inside environment
Choose environment to display from list of parent environments
Display objects as list or grid
Displays saved objects by type with short description
View in data viewer
View function source code
More file options
Create folder
Delete file
Rename file
Change directory
Path to displayed directory
A File browser keyed to your working directory. Click on file or directory name to open.
Version Control
Turn on at Tools > Project Options > Git/SVN
Added
Modified
Deleted
Renamed
Untracked
Stage files:
Commit staged files
Push/Pull to remote
View History
Current branch
Open shell to type commands
Show file diff to view file differences
Debug Mode
Use debug(), browser(), or a breakpoint and execute your code to open the debugger mode.
Launch debugger mode from origin of error
Open traceback to examine the functions that R called before the error occurred
Show Traceback
Rerun with Debug
Click next to line number to add/remove a breakpoint.
Highlighted line shows where execution has paused
Package Development
Create a new package with
File > New Project > New Directory > R Package
RStudio opens plots in a dedicated Plots pane
Navigate
Open in
Export
Delete
Delete
RStudio opens documentation in a dedicated Help pane

[Back]