01 - Boite à outils

PRO1036 - Analyse de données scientifiques en R

Tim Bollé

September 8, 2025

Boîte à outils

Les outils

Développement:

- R
- RStudio
- tidyverse
- R Markdown

Gestion et collaboration:

- Git
- GitHub

Objectif

Objectif du cours

À la fin de ce cours, vous pourrez:

- Analyser des données
- Analyser des données de manière `répétable`
- Analyser des données de manière répétable, avec des `outils de programmation modernes`
- Analyser des données de manière répétable et `collaborative`, avec des outils de programmation modernes

Répétabilité

> Que signifie conduire une analyse de donnée de manière répétable ?

À court-terme:

- Pouvons nous reproduire les tableaux et les figures à partir des données
- Est-ce que le code fait ce que nous voulons ?
- Pouvons-nous reconstruire pourquoi et comment nous avons obtenus les résultats

À long-terme:

- Peut-on réutiliser le code pour d'autres données ?
- Peut-on réutiliser le code pour faire autre chose ?

Les outils de la répérabilité

Scriptability \(\rightarrow\) R

Documentation et communication \(\rightarrow\) R Markdown

Gestion et collaboration \(\rightarrow\) Git/GitHub

R et RStudio

- R est un language de programmation `open-source`
- R est un environnement pour faire des `calculs statistiques` et de la `visualisation`
- De nombreuses autres applications sont disponibles grâce à des *`packages`*

- RStudio est un IDE (Environnement de Développement Intégré)
- C'est une interface pour R
- Pas nécessaire pour coder en R mais tellement pratique !

R packages

Les packages sont les *building blocks* de la reproductibilité. Ils contiennent de nombreuses fonctions réutilisables, de la documentation et données de test (Wickham and Bryan, 2023)

Nous allons en utiliser quelques une mais vous verrez que c'est tout une philosophie !

RStudio tour

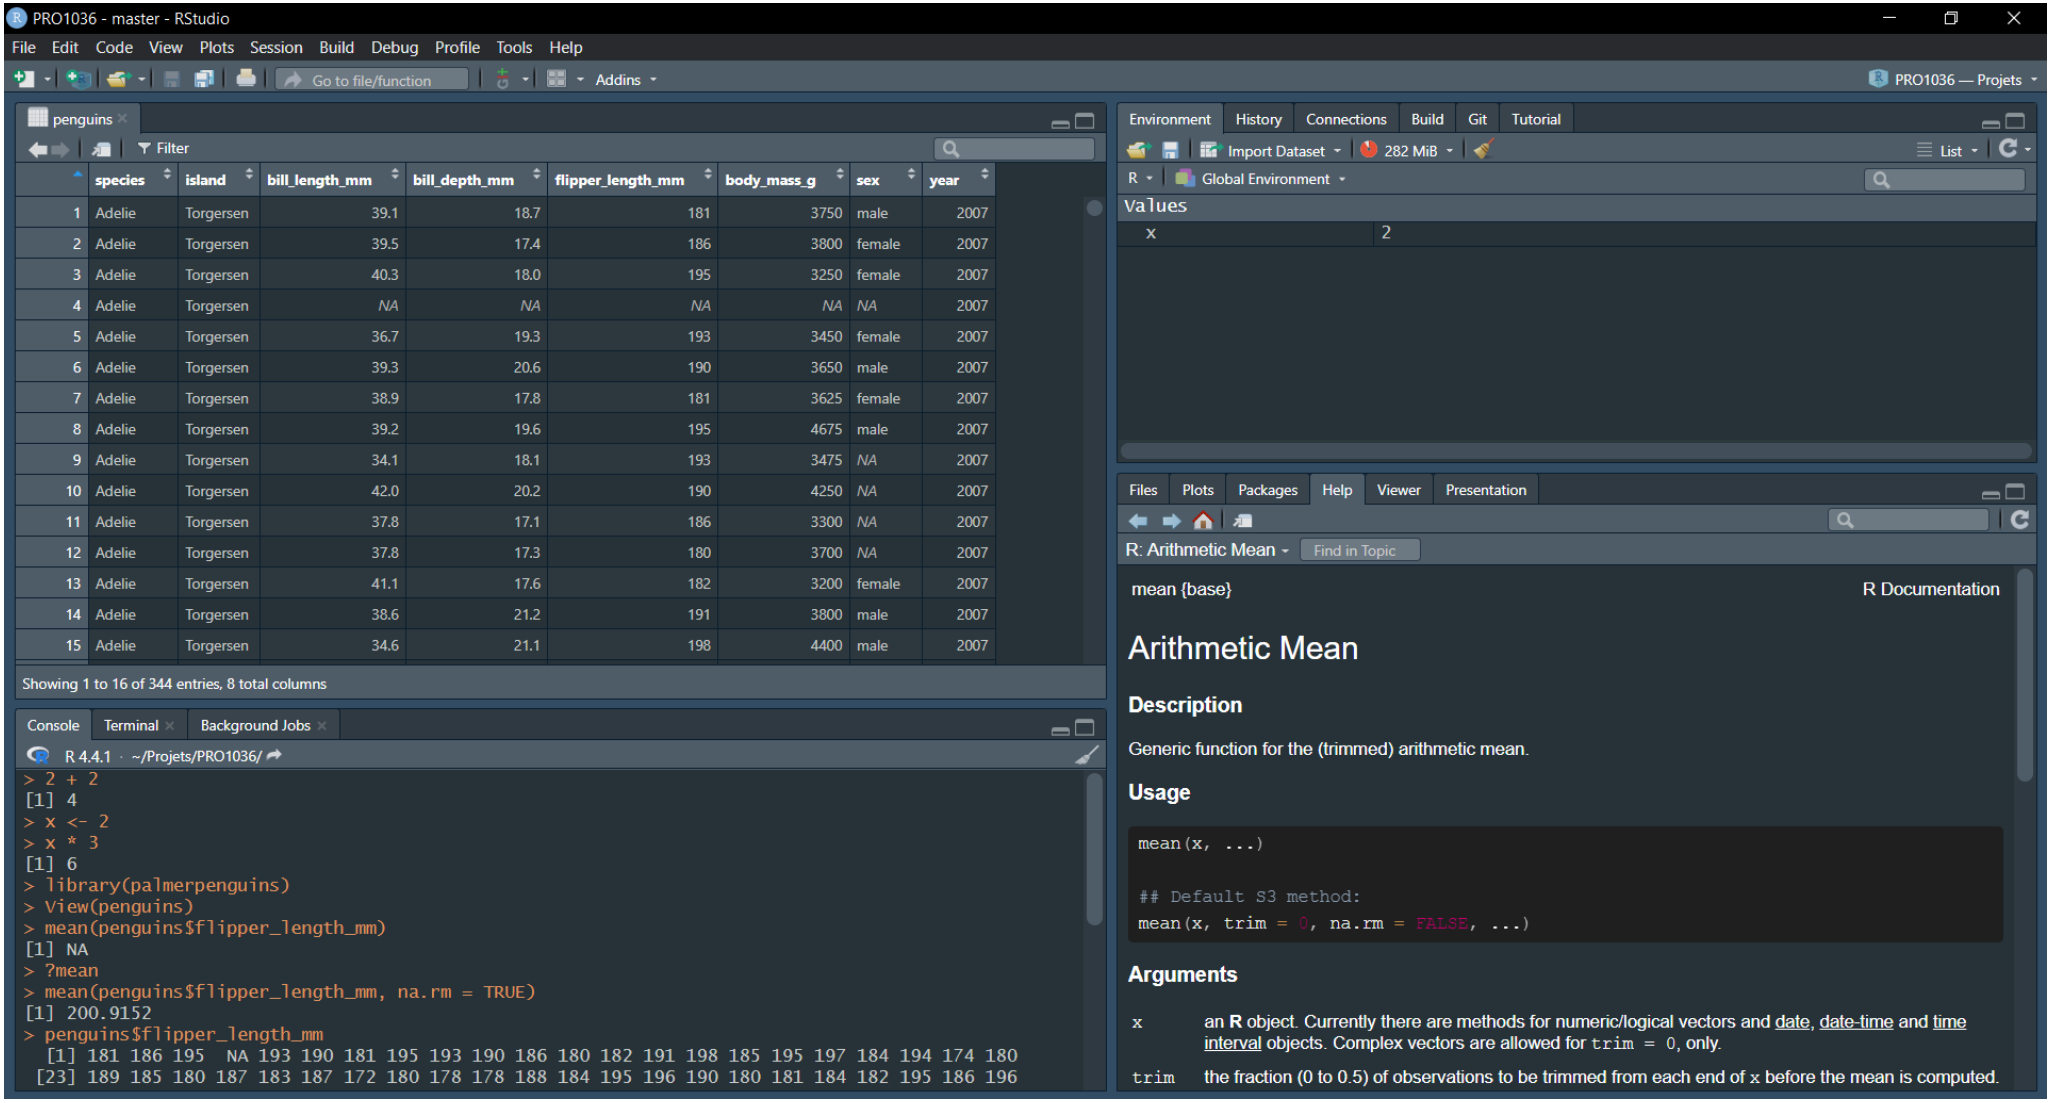

R 101

Les `fonctions` sont souvent des verbes, suivi de parenthèses, contenant des arguments:

```
1 fait_ca(avec_ca)
2 fait_ca(avec_ca, et_ca, et_encore_ca)
```

Les packages peuvent être installés avec `install.package` et chargés avec `library`:

```
1 install.packages("package_name")
2 library(package_name)
```

`$` permet d'accéder aux colonnes des tableaux

```
1 dataframe$var_name
```

`?` permet d'accéder à l'aide sur les fonctions

```
1 ?mean
```

Tidyverse

tidyverse.org

Le `Tidyverse` est une collection de packages développés pour faire de la data science

Il y a une philophie et une grammaire commune à tous ces packages, que nous allons apprendre.

R Markdown

rmarkdown.rstudio.com

`R Markdown` permet d'écrire des documents avec du code intégré (extension en `.Rmd`).

Va permettre de documenter et de communiquer directement nos analyses de données !

- Reproductible: À chaque fois qu'on génère le document, tout est exécuté depuis le début
- Syntaxe simple pour avoir des documents de qualité
- Le document se découpe en zones de texte et blocks de code

R Markdown

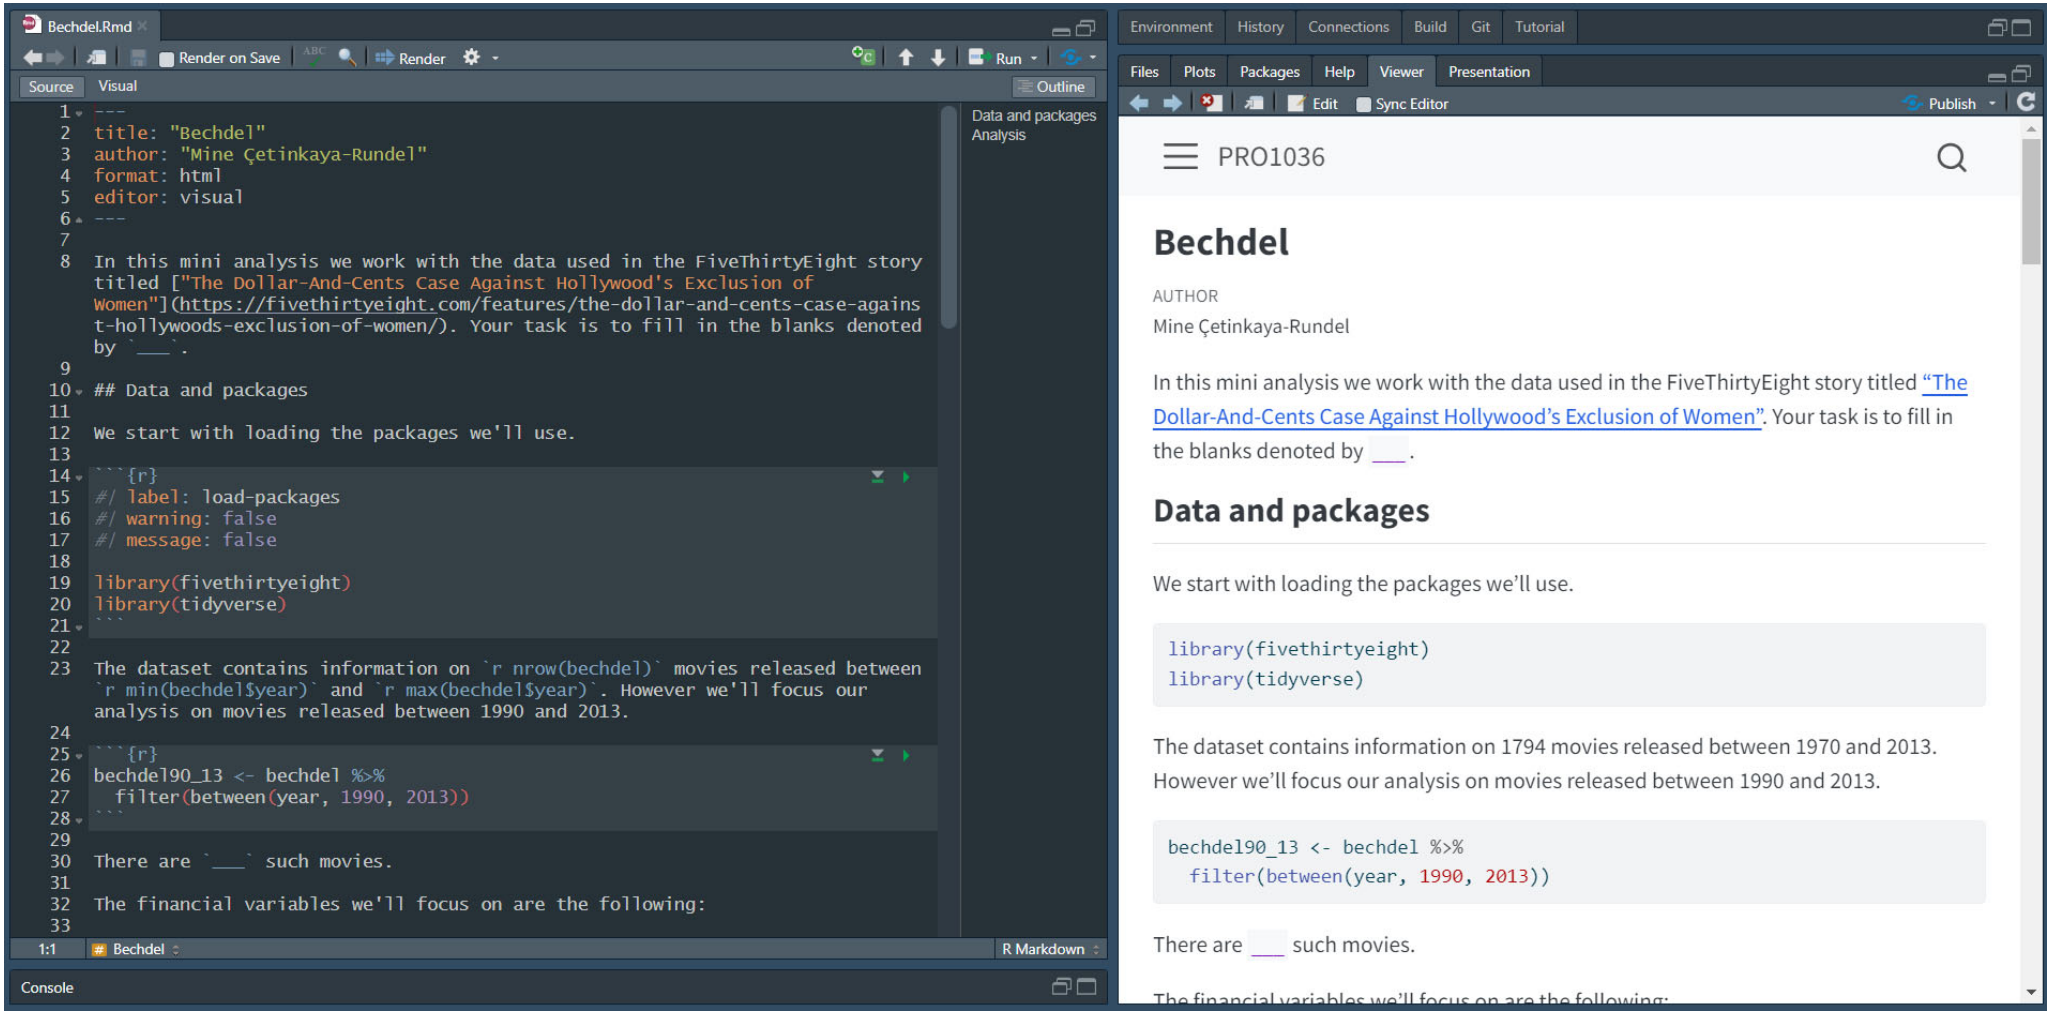
Bechdel.Rmd
Render on Save
Render
Run
Source
Visual
Outline
Data and packages Analysis
---
title: "Bechdel"
author: "Mine Çetinkaya-Rundel"
format: html
editor: visual

In this mini analysis we work with the data used in the FiveThirtyEight story titled ["The Dollar-And-Cents Case Against Hollywood's Exclusion of Women"](https://fivethirtyeight.com/features/the-dollar-and-cents-case-against-hollywoods-exclusion-of-women/). Your task is to fill in the blanks denoted by `___`.
Data and packages
We start with loading the packages we'll use.
```{r}
#| label: load-packages
#| warning: false
#| message: false
library(fivethirtyeight)
library(tidyverse)
```
The dataset contains information on `r nrow(bechdel)` movies released between `r min(bechdel$year)` and `r max(bechdel$year)`. However we'll focus our analysis on movies released between 1990 and 2013.
```{r}
bechdel90_13 <- bechdel %>%
filter(between(year, 1990, 2013))
```
There are `___` such movies.
The financial variables we'll focus on are the following:
1:1
Bechdel
R Markdown
Console
Environment
History
Connections
Build
Git
Tutorial
Files
Plots
Packages
Help
Viewer
Presentation
Edit
Sync Editor
Publish
PRO1036
Bechdel
AUTHOR
Mine Çetinkaya-Rundel
In this mini analysis we work with the data used in the FiveThirtyEight story titled "The Dollar-And-Cents Case Against Hollywood's Exclusion of Women". Your task is to fill in the blanks denoted by ___.
Data and packages
We start with loading the packages we'll use.
library(fivethirtyeight)
library(tidyverse)
The dataset contains information on 1794 movies released between 1970 and 2013. However we'll focus our analysis on movies released between 1990 and 2013.
bechdel90_13 <- bechdel %>%
filter(between(year, 1990, 2013))
There are ___ such movies.
The financial variables we'll focus on are the following:

R Markdown - Aide

Cheatsheet

`Help > Cheatsheet`

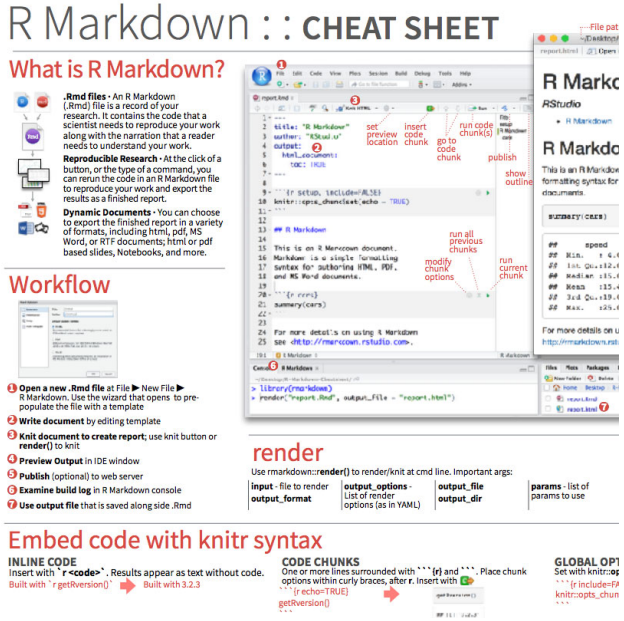

Markdown Quick Reference

`Help > Markdown Quick Reference`

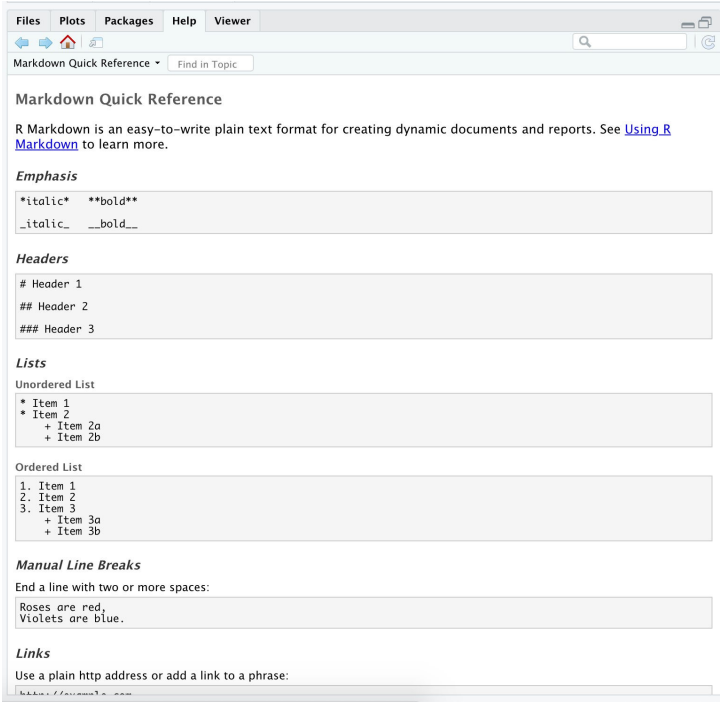

Boîte à outils

Les outils

Développement:

- R
- RStudio
- tidyverse
- R Markdown

Gestion et collaboration:

- Git
- GitHub

Git et GitHub

- Git est un outil de `gestion de version`
  - Comme le *track changes* sur Word
- Très populaire dans le monde de la programmation

- GitHub est un plateforme de stockage de `repo` Git
  - Comme un Onedrive/Dropbox pour Git
- Nous allons essayer de l'utiliser pour… tout !

Pourquoi la gestion de version ?

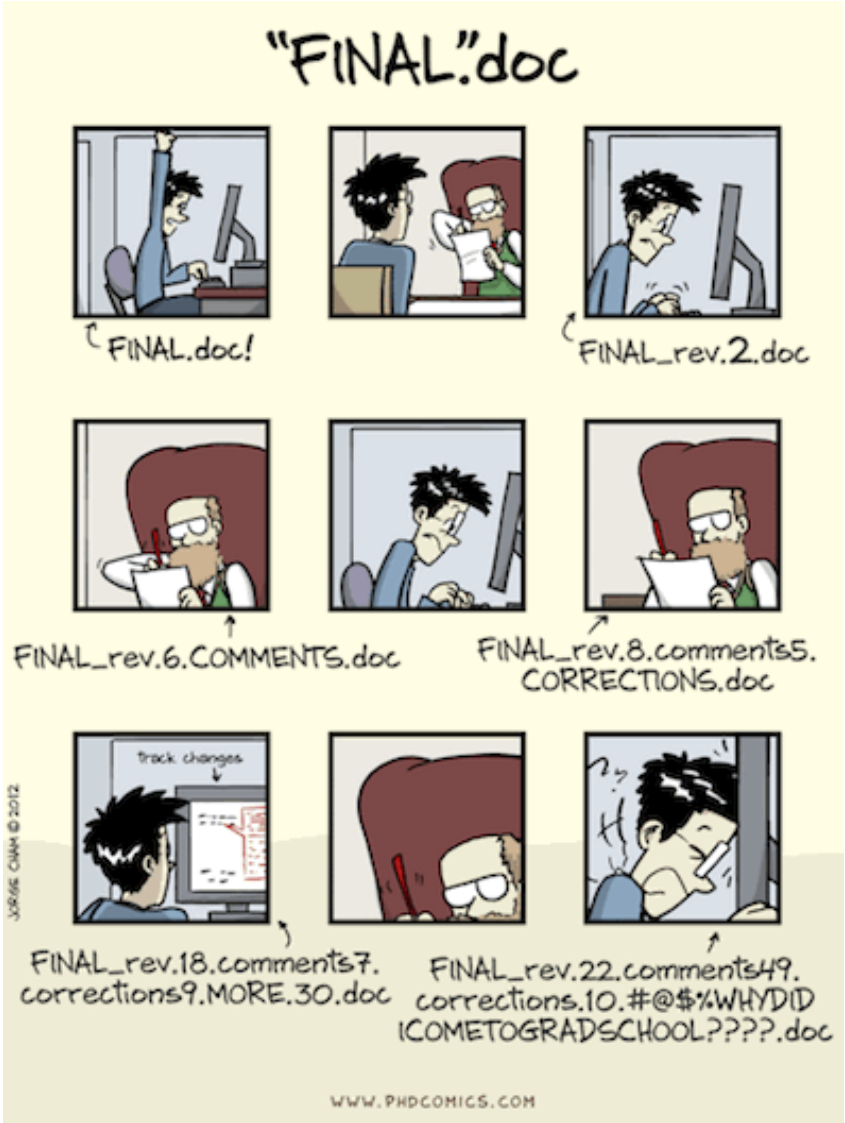

PhD Comics

Fonctionnement

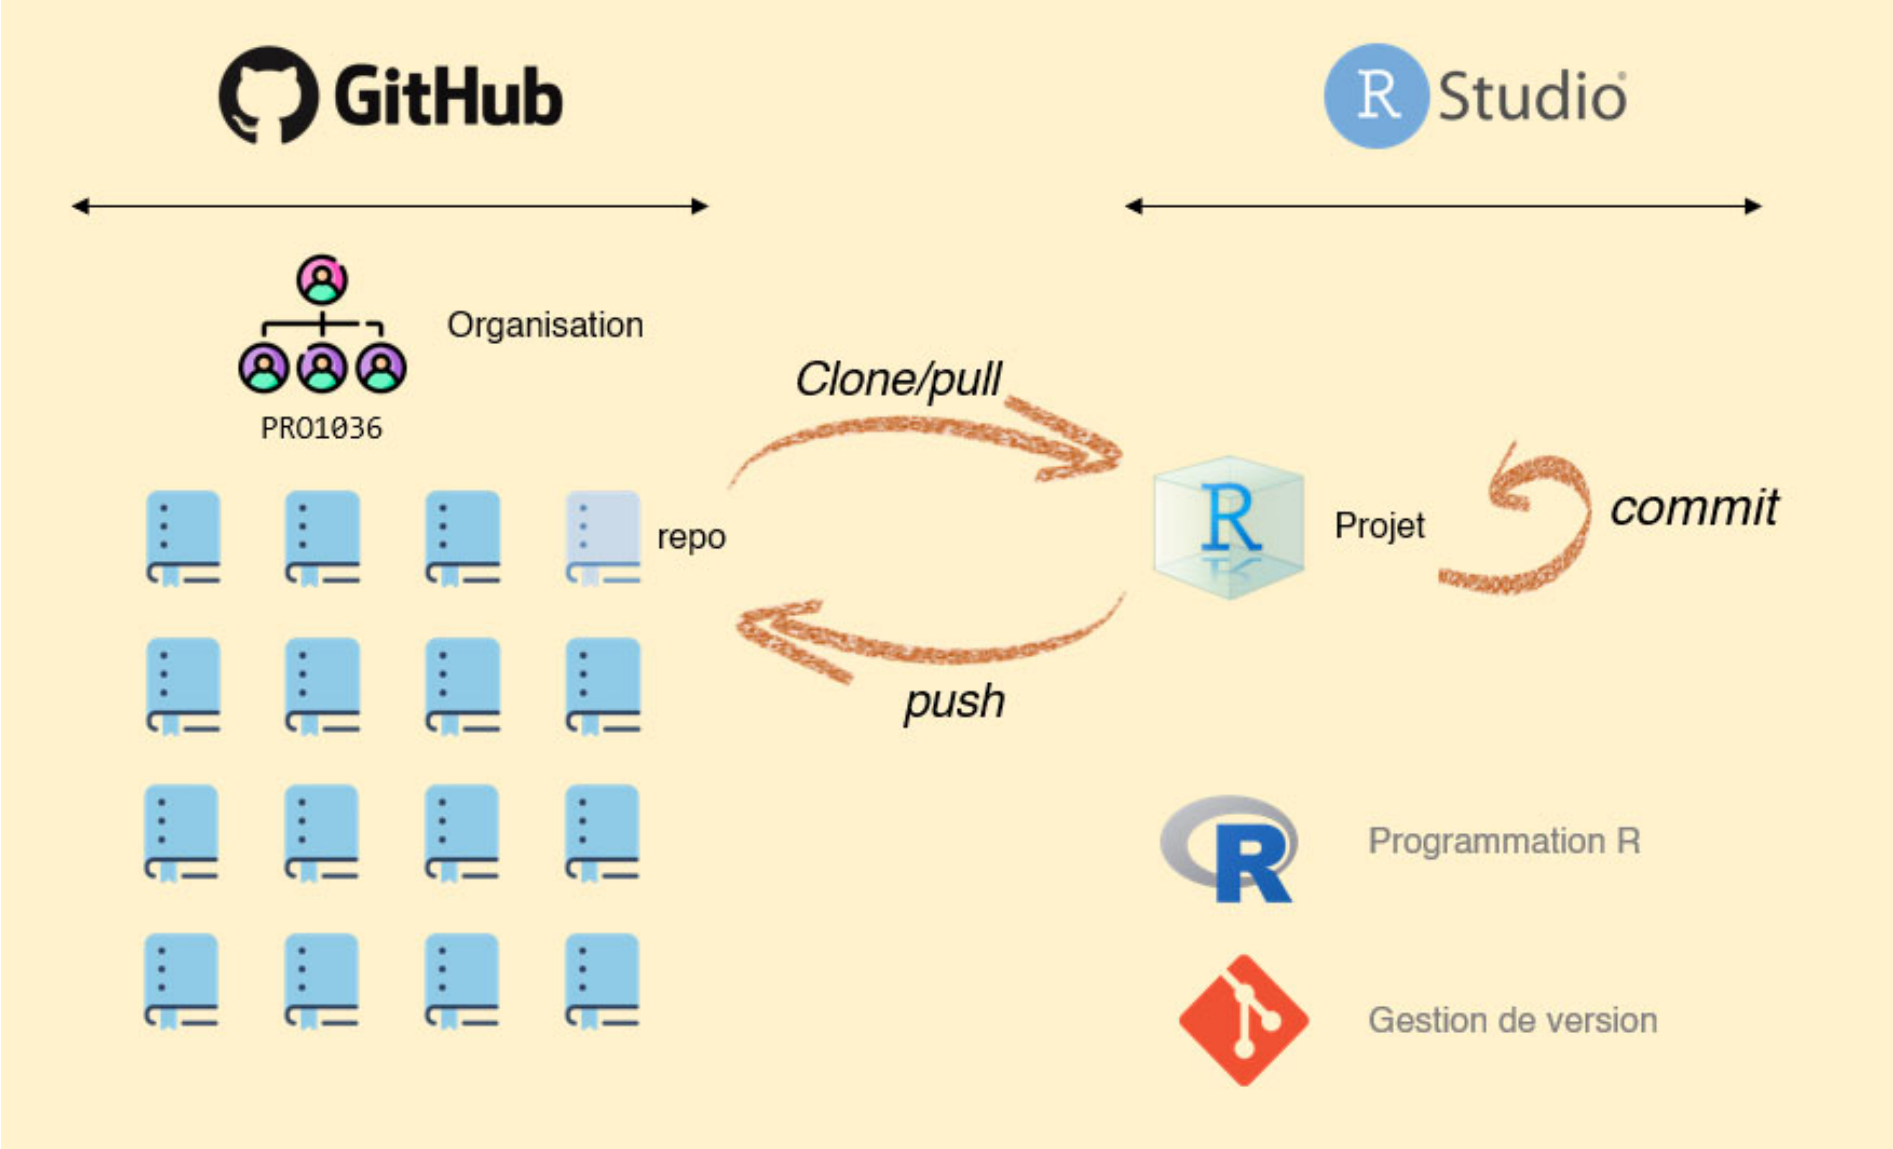

Mise en place

Git peut être utilisé depuis le terminal de commande

- Utilisation plus avancée
- Nous pouvons normalement tout faire depuis R Studio

Github:

- Créez un compte avec votre adresse UQTR
- Vérifiez votre adresse courriel

À vous de jouer !

Votre première analyse de données

UN Votes

Pour le faire chez vous:

- Ouvrez RStudio
- `Nouveau Projet > Version Control > Git`
- Entrez l'url: https://github.com/PRO1036/unvotes
- Choisissez un dossier sur l'ordinateur
- Ouvrez le fichier `unvotes.rmd`
- Validez l'installation des packages.
- Cliquez sur `knit`

Références

Wickham, H. and Bryan, J. (2023). *R Packages: Organize, Test, Document, and Share Your Code* (2nd edition). O'Reilly Media.