

L'enseignement et la formation au logiciel R : un retour d'expérience

Julien Barnier
Centre Max Weber
`julien.barnier@ens-lyon.fr`
Twitter : @lapply

19 novembre 2015

Présentation

Présentation

Utilisateur (irrégulier) de R depuis une quinzaine d'années.

Initiateur du document *Introduction à R* et du package `questionr`.

Donne des formations à R depuis 7 ans. Public de chercheurs et de doctorants.

Type de formation

Formations

Plan d'une formation type de 2 jours :

Formations

Plan d'une formation type de 2 jours :

- ▶ **Première demi-journée** : présentation de l'interface. Familiarisation avec la ligne de commande de manière très progressive, puis utilisation de scripts. Début de travail avec des données.

Formations

Plan d'une formation type de 2 jours :

- ▶ **Première demi-journée** : présentation de l'interface. Familiarisation avec la ligne de commande de manière très progressive, puis utilisation de scripts. Début de travail avec des données.

- ▶ **Deuxième demi-journée** : poursuite du travail sur des données, première analyses statistiques simples.

Formations

Plan d'une formation type de 2 jours :

- ▶ **Première demi-journée** : présentation de l'interface. Familiarisation avec la ligne de commande de manière très progressive, puis utilisation de scripts. Début de travail avec des données.
- ▶ **Deuxième demi-journée** : poursuite du travail sur des données, première analyses statistiques simples.
- ▶ **Troisième demi-journée** : notion d'indexation et de recodage.

Formations

Plan d'une formation type de 2 jours :

- ▶ **Première demi-journée** : présentation de l'interface. Familiarisation avec la ligne de commande de manière très progressive, puis utilisation de scripts. Début de travail avec des données.
- ▶ **Deuxième demi-journée** : poursuite du travail sur des données, première analyses statistiques simples.
- ▶ **Troisième demi-journée** : notion d'indexation et de recodage.
- ▶ **Quatrième demi-journée** : Approche "marketing" pour donner envie après la demi-journée précédente souvent difficile : cartographie, graphiques, rmarkdown, TraMineR...

Quel R ?

The screenshot shows the RStudio interface with two main panes. The left pane displays R code for a presentation slide, and the right pane shows the rendered slide content.

Left Pane (Script Editor):

```

23 Initiateur du document *Introduction à R*.
24
25
26 Utilisateur (irrégulier) de R depuis une quinzaine d'années.
27
28 \pause
29
30 ---{R, eval=FALSE}
31 x <- "Chihuahua"
32 x = "Chihuahua"
33 X "Chihuahua"
34 ---
35
36
37 # Type de formation
38
39 ## Formations
40
41 I[](img/chat_perplexe.jpg)
42
43
44 ## Formations
45
46 I[](img/chat_necontent.jpg)
47
48
49 ## Formations
50
51 Plan d'une formation type de 2 jours :
52
53 \pause
54
55 **Première demi-journée : présentation de l'interface. Familiarisation
avec la ligne de commande de manière très progressive, puis utilisation
de scripts. Début de travail avec des données.
56
57 **Deuxième demi-journée : poursuite du travail sur des données,
première analyses statistiques simples.
58
59 **Troisième demi-journée : notion d'indexation et de recodage.
60
61 **Quatrième demi-journée : Approche "marketing" pour donner envie
après la demi-journée précédente souvent difficile : cartographie,
graphiques, rmarkdown, TrAMNeR...
62
63
62.1 Formations
R Markdown

```

Right Pane (Preview Window):

```

processing file: slides.Rmd
List of 1
 $ include: logi FALSE
 ..... | 60%
 ordinary text without R code
 ..... | 80%
 Label: unnamed-chunk-1 (with options)
 List of 1
 $ eval: logi FALSE
 ..... | 100%
 ordinary text without R code

```

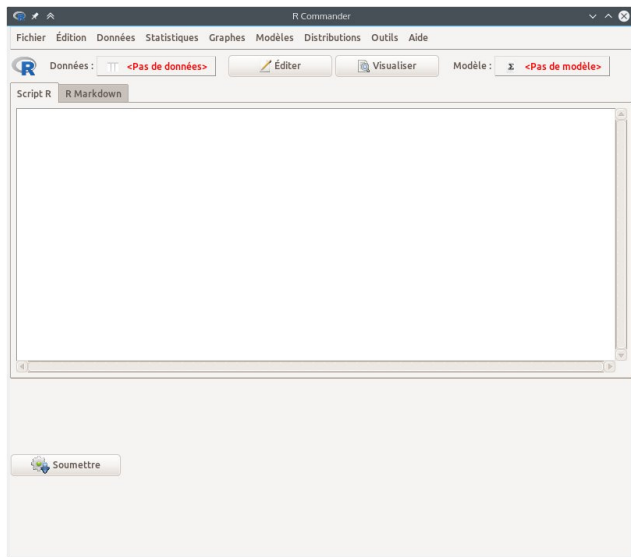
Bottom Pane (File Explorer):

Name	Size	Modified
..		
.Rhistory	2.8 KB	Nov 17, 2015, 9:35 AM
ined_ehess_2015.Rproj	203 B	Nov 2, 2015, 11:30 AM
notes_interv.Rmd	7 KB	Nov 17, 2015, 3:56 PM
slides.Rmd	4.5 KB	Nov 17, 2015, 3:03 PM
slides.pdf	245.9 KB	Nov 17, 2015, 11:37 AM
slides.html	470.2 KB	Nov 17, 2015, 11:25 AM
custom.css	1.3 KB	Nov 17, 2015, 9:48 AM
img		
slides_elisabeth.Rmd	4.4 KB	Nov 17, 2015, 4:03 PM

Incontournable aujourd'hui :

- ▶ notion de projets (permet d'éviter les problèmes de répertoires de travail)
- ▶ interface unifiée quel que soit le système d'exploitation
- ▶ séparation de l'écran en quatre volets qui aide à comprendre la logique de R
- ▶ coloration syntaxique, auto-complétion, aide intégrée. . .

R Commander



R Commander

Dès le départ, choix de ne pas utiliser *R Commander*.

- ▶ pas convaincu par l'interface
- ▶ trop vite limité
- ▶ on perd en grande partie l'avantage de créer des scripts : efficacité, reproductibilité

Point de vue : *R Commander* est adapté si on sait dès le départ qu'on pourra se contenter des fonctionnalités proposées par l'interface.

Interfaces ponctuelles

Aujourd'hui plutôt une démarche "mixte" :

- ▶ On privilégie le code : commandes et scripts dès le départ.
- ▶ En complément ou en support, utilisation ponctuelle d'interfaces graphiques appelées depuis R.
- ▶ Principe de base : ces interfaces ne doivent pas exécuter de commande ou modifier les données.

Interfaces ponctuelles

Aujourd'hui plutôt une démarche "mixte" :

- ▶ On privilégie le code : commandes et scripts dès le départ.
- ▶ En complément ou en support, utilisation ponctuelle d'interfaces graphiques appelées depuis R.
- ▶ Principe de base : ces interfaces ne doivent pas exécuter de commande ou modifier les données.

Exemples :

- ▶ `irec`, `iorder`, `icut` du package `questionr`
- ▶ `imca` (package en cours de développement)

`shiny` et `htmlwidgets` facilitent le développement de ces interfaces.



Évolution du code

Hier :

```
tmp.h <- hdv2003[hdv2003$sexe == "Homme",]  
tmp.f <- hdv2003[hdv2003$sexe == "Femme",]  
par(mfrow=c(2,1), mar=c(3,3,1,1))  
boxplot(age ~ qualif, data=tmp.h, ylim=c(0,100))  
boxplot(age ~ qualif, data=tmp.f, ylim=c(0,100))
```

Évolution du code

Hier :



Évolution du code


Aujourd'hui :

```
library(ggplot2)

ggplot(data=hdv2003) +
  geom_boxplot(aes(x = qualif, y = age)) +
  facet_grid(sexe ~ .)
```

Évolution du code

Aujourd'hui :



Évolution du code

Hier :

```
tmp <- hdv2003[hdv2003$qualif == "Employe", ]
tab1 <- aggregate(tmp$age, list(tmp$sexe), mean)
names(tab1) <- c("sexe", "age_mean")
tab2 <- aggregate(tmp$age, list(tmp$sexe), median)
names(tab2) <- c("sexe", "age_median")
merge(tab1, tab2)
```

```
##      sexe age_mean age_median
## 1 Femme 47.05221      45
## 2 Homme 44.69792      45
```

Évolution du code

Aujourd'hui :

```
library(dplyr)

hdv2003 %>%
  filter(qualif == "Employe") %>%
  group_by(sexe) %>%
  summarise(age_mean = mean(age),
            age_median = median(age))
```

```
## Source: local data frame [2 x 3]
##
##   sexe age_mean age_median
##   (fctr)   (dbl)     (dbl)
## 1 Homme 44.69792      45
## 2 Femme 47.05221      45
```

Quels packages en formation ?

Jusque là, la formation se contentait de R “de base” et du package `questionr` pour des fonctions facilitant des besoins courants.

Aujourd’hui, et de plus en plus, certains packages semblent incontournables :

- ▶ `ggplot2`
- ▶ `dplyr`, `tidyr`
- ▶ `rmarkdown`
- ▶ ...

Quels packages en formation ?

Avantages : fonctionnalités supplémentaires, syntaxe simplifiée et cohérente.

- ▶ affichage de légendes dans des graphiques
- ▶ code avec des *pipes*, plus lisible
- ▶ documents en Markdown et export multi-formats

Inconvénients : complexité supplémentaire, logiques de syntaxe et de code différentes.

Biais : difficile de ne pas les introduire quand on les utilise au quotidien et que les réponses aux questions posées nous viennent spontanément avec ces packages.

Quels packages en formation ?

Question : Quand et comment les introduire ?

Pas encore de réponse claire.

- ▶ `ggplot2` : dans un deuxième temps.
- ▶ `dplyr`, `tidyr` : pas intégrés aujourd'hui, réflexion en cours.
- ▶ `rmarkdown` : présentation en "bonus".

Accompagnement

Outils et documentation

Francophones :

- ▶ La documentation en français d'introduction est de plus en plus complète et abondante.
- ▶ Listes de discussion (R-soc, semin-r...) : peu utilisées.
- ▶ Forum du Cirad : utilisé, mais pas forcément très connu.
- ▶ MOOC

Anglophones :

- ▶ *StackOverflow*
- ▶ plein d'autres !

Groupes d'utilisateurs

- ▶ Exemple du groupe d'utilisateurs de R sur Lyon
- ▶ Exemple de l'*Espace quanti* au Centre Max Weber

Merci de votre attention !

Ressources utiles

- ▶ Document *Introduction à R* :
<http://alea.fr.eu.org/pages/intro-R>
- ▶ Package `questionr` :
<http://alea.fr.eu.org/pages/questionr>
- ▶ Site de `ggplot2` : <http://ggplot2.org/>
- ▶ Package `dplyr` :
<https://cran.r-project.org/web/packages/dplyr>
- ▶ Package `explor` et fonction `imca` (instable, en cours de développement) : <https://github.com/juba/explor>
- ▶ Package associé `scatterD3` permettant des nuages de points interactifs : <https://github.com/juba/scatterD3>