



# Initiation

## Formation 2014

- Introduction
- Premières additions
- Importation de données tabulées
- Manipulation d'objets plus complexes
- Fonctions mathématiques
- Programmation
- Fonctions propre à R pour la manipulation de tableaux
- Les graphiques
- Exportation
- Un cas d'école

## Introduction à l'environnement R

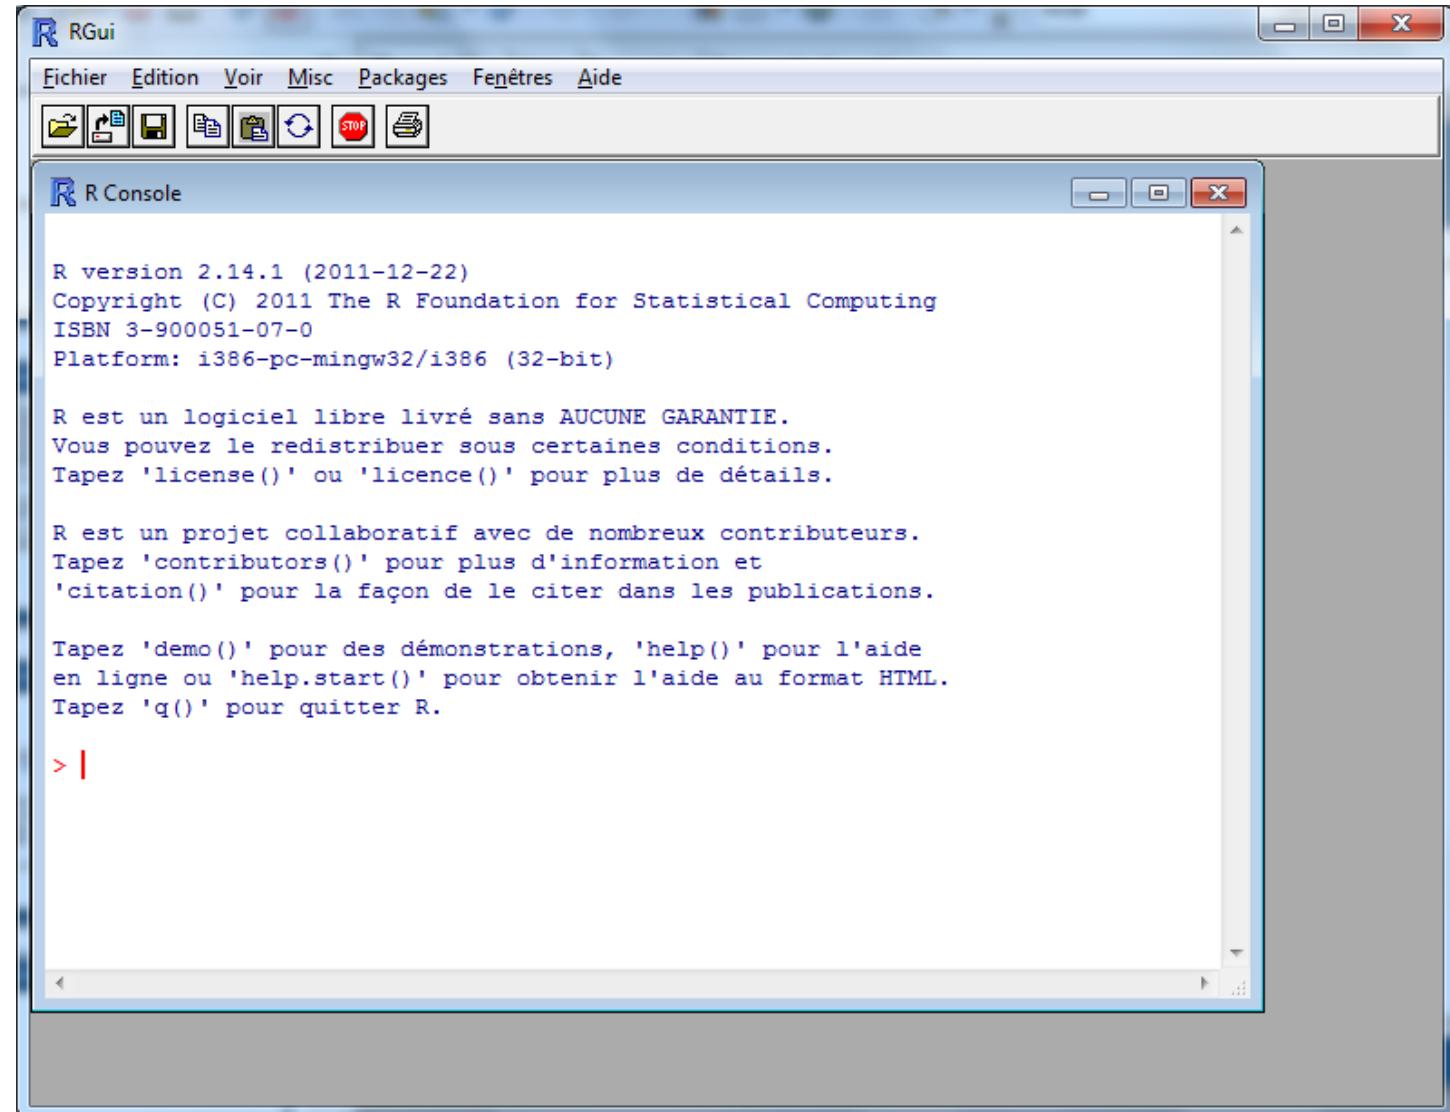
- R : pour quoi faire ?
  - traitement de données, analyses statistiques, graphs
  - très efficace pour traiter en routine les jeux de données les plus conséquents (par exemple, automatiser formatage des données, analyses et graphs en un seul script)
  - création de données (modélisation, simulation... par ex : simuler les résultats attendus sous des hypothèses alternatives)
  - toujours à la pointe en traitement statistique (ajouts permanents)
- R : pour *ne pas faire* quoi ?
  - ce que l'on sait faire mieux et plus vite ailleurs (e.g. Excel)
  - algèbre symbolique (e.g. Mathematica)
  - ...

- R est un logiciel **libre**, **gratuit** et **multiplateforme** (windows, linux et mac) distribué par GNU Public Licence très utilisé pour l'analyse **statistique**. La version de base dispose d'un grand nombre d'outils **analytiques** et **graphiques** permettant de manipuler, de traiter et de représenter des données de nature très différentes. Son développement met à contribution des utilisateurs qui peuvent créer de nouveaux paquets (« **packages** ») rendant les possibilités d'utilisation immenses dans des domaines d'études très différents (écologie, analyse sensorielle, psychologie, économie...) et faisant intervenir des techniques très diverses (analyse multivariée, modélisation linéaire et non linéaire, statistique spatiale, classification, tests statistiques...).
- Le **partage** grandissant de nouveaux paquets rend ce logiciel très **dynamique** et qui s'enrichit jour après jour.
- R est également un langage de programmation basé sur le calcul matriciel. La manipulation d'objets de type vecteur, liste, matrice permet une flexibilité de programmation d'algorithmes plus ou moins évolués répondant aux attentes de chacun.
- Parmi les paquets, il en existe permettant d'interfacer avec d'autres outils tels que PostgreSQL et MySQL pour les bases de données, le logiciel libre GRASS pour le SIG, RExcel pour excel ou encore Latex et OpenDocument pour l'exportation de résultats.

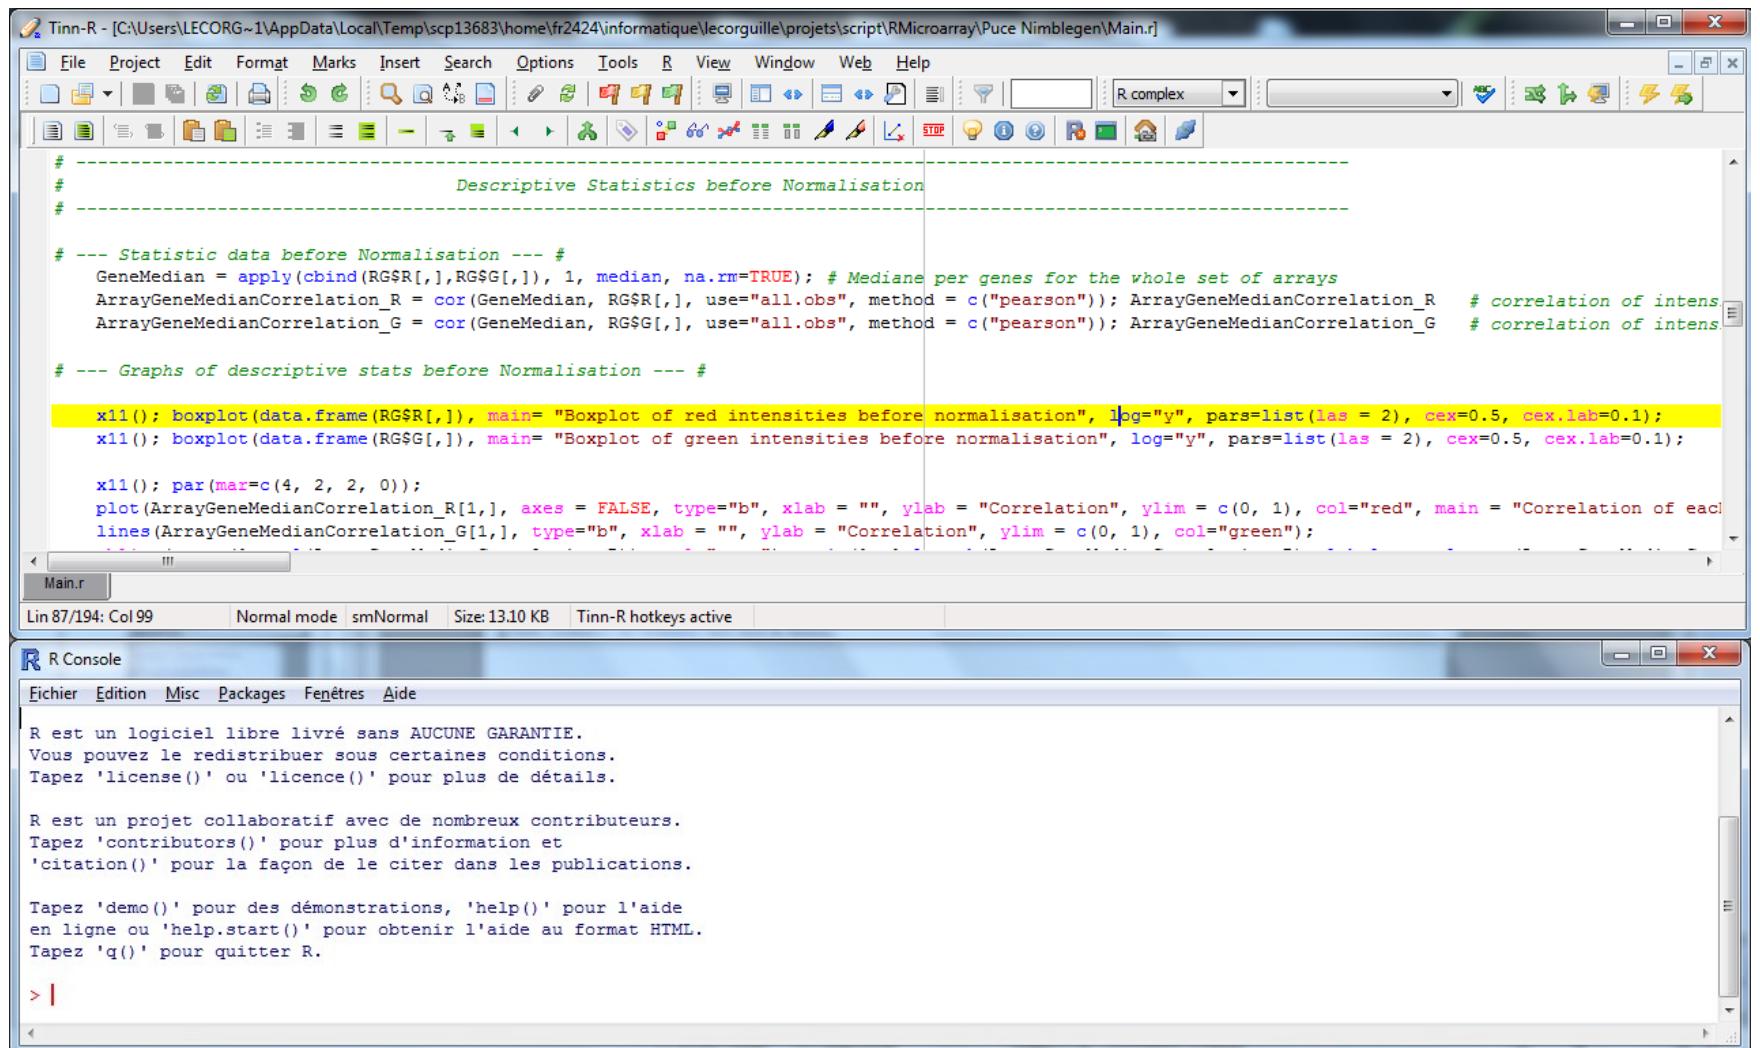
<http://abcdr.2sigma.fr/>

- Quelques bons tutoriels
  - [http://cran.r-project.org/doc/contrib/Paradis-rdebuts\\_fr.pdf](http://cran.r-project.org/doc/contrib/Paradis-rdebuts_fr.pdf)
  - <http://w3.jouy.inra.fr/unites/miaj/public/formation/initiationRv4.pdf>
  - <http://cran.r-project.org/other-docs.html>
- R Reference Card
  - <http://cran.r-project.org/doc/contrib/Short-refcard.pdf>
  - <http://cran.r-project.org/doc/contrib/YanchangZhao-refcard-data-mining.pdf>

## • RGui



- Tinn-R + RGui



The screenshot shows two windows: Tinn-R IDE and R Console.

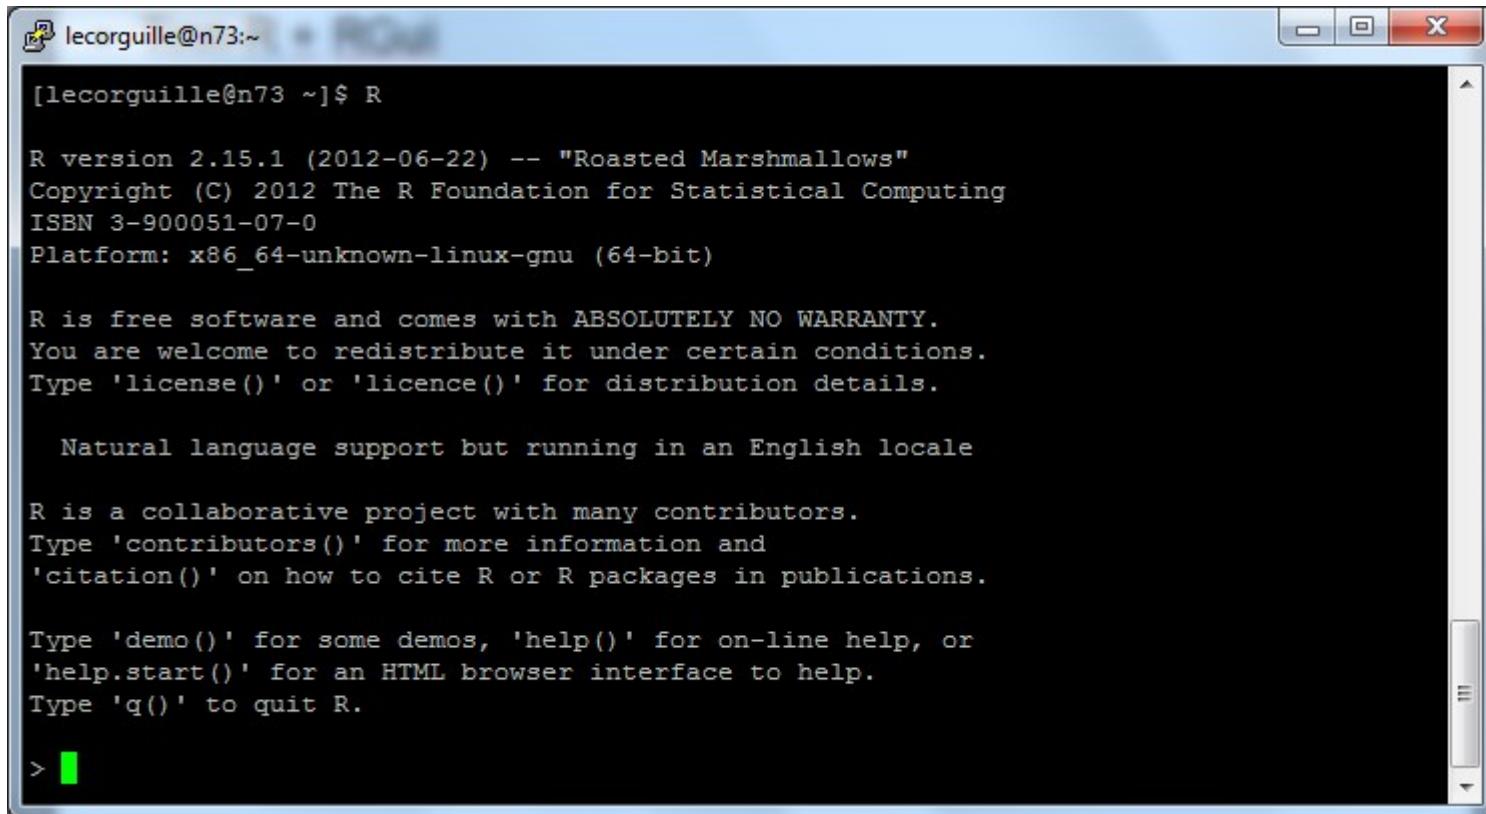
**Tinn-R IDE (Top Window):**

- File menu: File, Project, Edit, Format, Marks, Insert, Search, Options, Tools, R, View, Window, Web, Help.
- Toolbar: Includes icons for file operations like Open, Save, Print, and various R-related functions.
- Code Editor: Displays an R script named "Main.r". The code performs descriptive statistics, correlation calculations, and generates boxplots and correlation plots for red and green intensities.
- Status Bar: Shows "Lin 87/194: Col 99", "Normal mode", "smNormal", "Size: 13.10 KB", and "Tinn-R hotkeys active".

**R Console (Bottom Window):**

- File menu: Fichier, Edition, Misc, Packages, Fenêtres, Aide.
- Text Area: Displays the R startup message in French, including information about the software being free and open-source, its contributors, and how to get help.
- Prompt: Shows the R prompt "> |".

- R



[lecorguille@n73:~]\$ R

R version 2.15.1 (2012-06-22) -- "Roasted Marshmallows"  
Copyright (C) 2012 The R Foundation for Statistical Computing  
ISBN 3-900051-07-0  
Platform: x86\_64-unknown-linux-gnu (64-bit)

R is free software and comes with ABSOLUTELY NO WARRANTY.  
You are welcome to redistribute it under certain conditions.  
Type 'license()' or 'licence()' for distribution details.

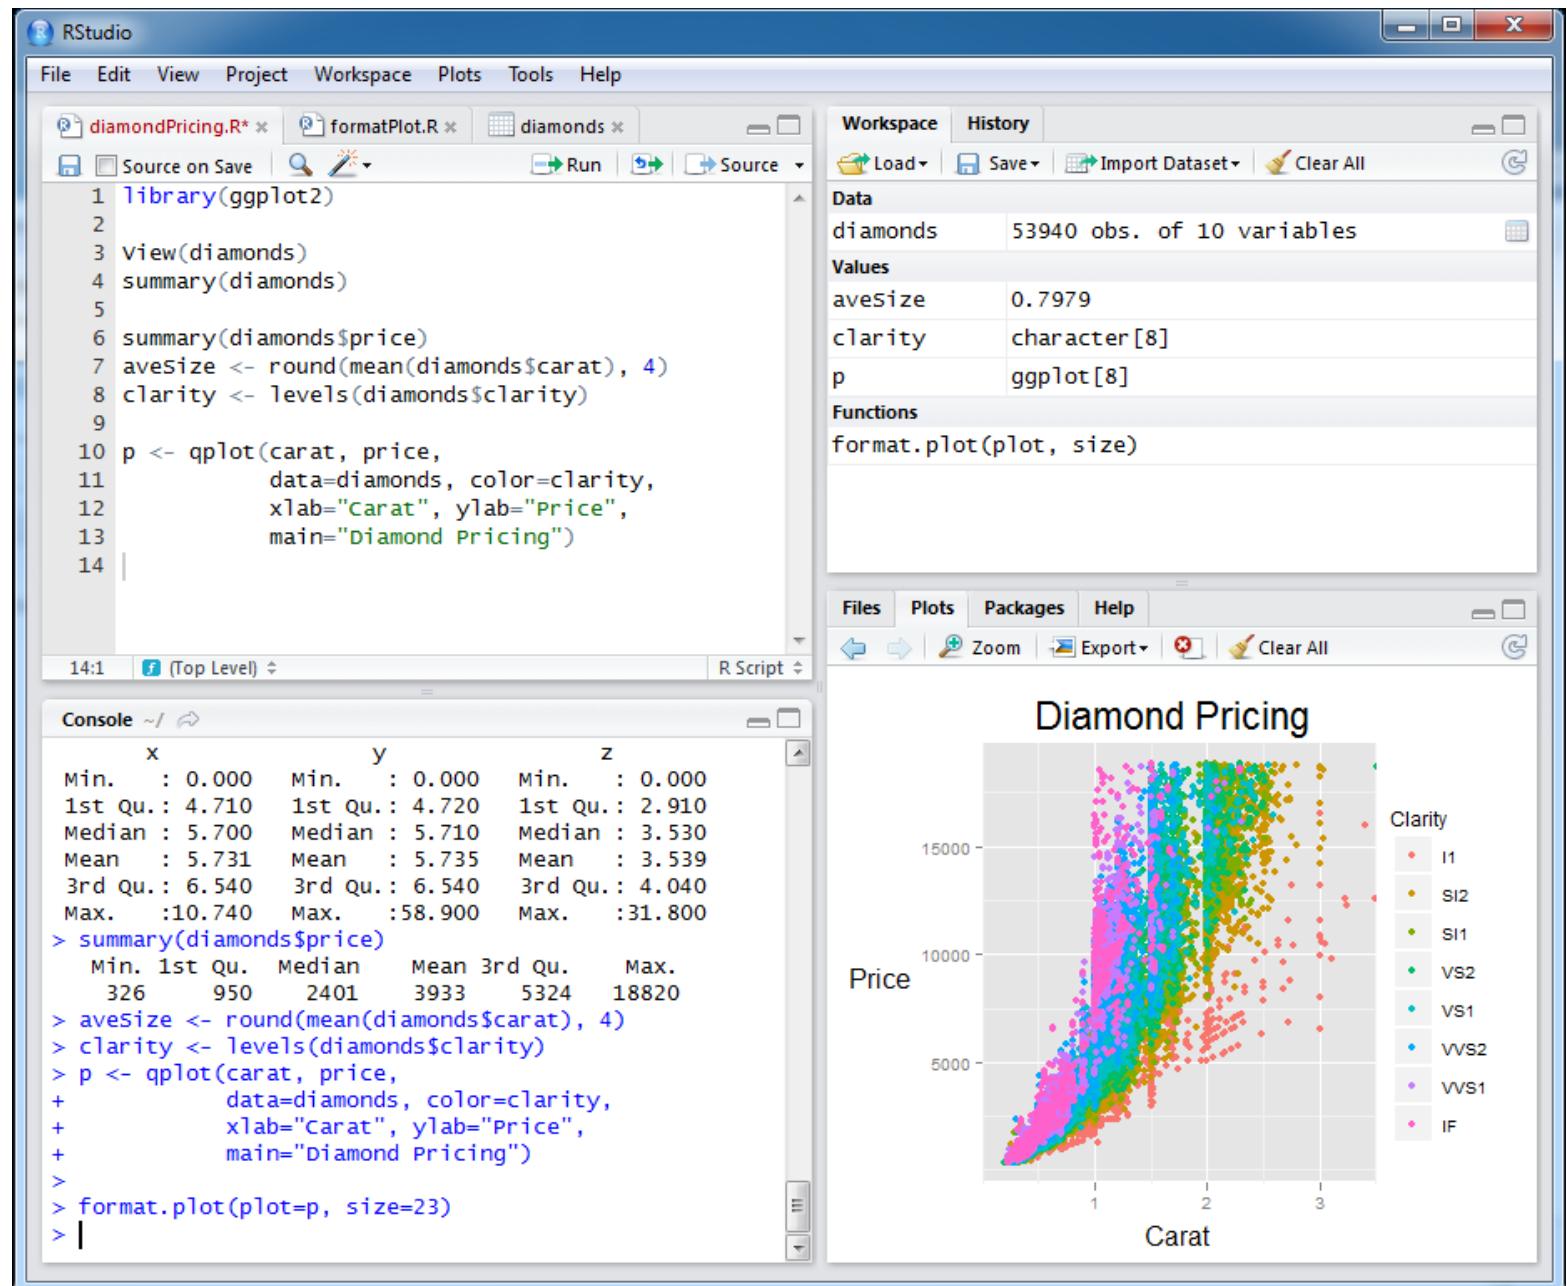
Natural language support but running in an English locale

R is a collaborative project with many contributors.  
Type 'contributors()' for more information and  
'citation()' on how to cite R or R packages in publications.

Type 'demo()' for some demos, 'help()' for on-line help, or  
'help.start()' for an HTML browser interface to help.  
Type 'q()' to quit R.

> █

- RStudio



The screenshot shows the RStudio interface with the following components:

- Script Editor:** Displays the following R code in the `diamondPricing.R*` file:

```

1 library(ggplot2)
2
3 view(diamonds)
4 summary(diamonds)
5
6 summary(diamonds$price)
7 aveSize <- round(mean(diamonds$carat), 4)
8 clarity <- levels(diamonds$clarity)
9
10 p <- qplot(carat, price,
11             data=diamonds, color=clarity,
12             xlab="Carat", ylab="Price",
13             main="Diamond Pricing")
14

```

- Console:** Displays the results of running the R code, including summary statistics for the `x`, `y`, and `z` variables, and the `summary(price)` command.
- Workspace Browser:** Shows the `diamonds` dataset with 53940 observations and 10 variables, and the `p` object as a ggplot [8].
- Plot Viewer:** A scatter plot titled "Diamond Pricing" showing Price (Y-axis, 0 to 15000) versus Carat (X-axis, 0 to 3). The plot uses color to represent Clarity levels, with a legend on the right side.

- Library

- Plusieurs bibliothèques de fonctions sont installées par défaut : base, graphics, stats, etc. . .
- De nombreuses bibliothèques plus spécialisées doivent être installées depuis le CRAN ou via le projet Bioconductor (genomic, microarray).
  - CRAN : `install.packages("cluster")` → support.abims@sb-roscott.fr
  - Bioconductor : `biocLite("affy")` → support.abims@sb-roscott.fr
  - Ces library spécifiques doivent être chargés à chaque session avant leurs utilisations

```
> library("cluster")
```

# Premières additions

- Facile

```
> 1
[1] 1

> 1 + 1
[1] 2

> "Hello World!"
[1] "Hello World!"
```

- Stockage dans des variables

- Les fonctions

Toujours :      `nom_de_la_fonction()`

- Les arguments de fonction

- Parfois :      `fct(arg1, arg2, arg3)`
- Parfois :      `fct(nom_arg1=arg1, nom_arg2=arg2)`
- Parfois :      `fct(arg1, nom_arg2=arg2)`

Bienvenue dans un monde du libre

- `help(mean)`
- `?mean`
- **Google**
  - R mean (2,110,000,000 results)
  - GNU R mean (5,940,000 results)



[R-Mean MySpace](#)

## mean {base}

### Arithmetic Mean

#### Description

Generic function for the (trimmed) arithmetic mean.

#### Usage

```
mean(x, ...)

## Default S3 method:
mean(x, trim = 0, na.rm = FALSE, ...)
```

#### Arguments

- x An R object. Currently there are methods for numeric/logical vectors and [date](#), [date-time](#) and [time interval](#) objects, and for data frames all of whose columns have a method allowed for trim = 0, only.
- trim the fraction (0 to 0.5) of observations to be trimmed from each end of x before the mean is computed. Values of trim outside that range are taken as the nearest endpoint.
- na.rm a logical value indicating whether NA values should be stripped before the computation proceeds.
- ... further arguments passed to or from other methods.

#### Value

If trim is zero (the default), the arithmetic mean of the values in x is computed, as a numeric or complex vector of length one. If x is not logical (coerced to numeric), numeric (in NA\_real\_) is returned, with a warning.

If trim is non-zero, a symmetrically trimmed mean is computed with a fraction of trim observations deleted from each end before the mean is computed.

#### References

Becker, R. A., Chambers, J. M. and Wilks, A. R. (1988) *The New S Language*. Wadsworth & Brooks/Cole.

#### See Also

[weighted.mean](#), [mean.POSIXct](#), [colMeans](#) for row and column means.

#### Examples

```
x <- c(0:10, 50)
xm <- mean(x)
c(xm, mean(x, trim = 0.10))
```

- pour résumer : comment trouver de l'aide ?
  - si on connaît le nom de la fonction: `help(fonction)` ou utiliser l'aide dans R-studio
  - sinon, pour les bases : utiliser les tutoriaux et les listes de fonction
  - pour aller plus loin : les livres (en particulier : R book)
  - le cas particulier qui m'intéresse n'est jamais exactement celui qui est décrit dans le bouquin... : écumer les forums de discussion sur internet.

## Importation de données tabulées

- La navigation
  - Le répertoire de travail est par défaut celui dans lequel vous lancez R
  - Il peut être changé de 2 manières :
    - Click-bouton via les menus (RGui ou Rstudio)
    - Fonction (pour les scripts en mode batch sur le serveur de calcul)

```
setwd("/projet/login/data/R")
```

```
setwd("../data/R")
```



**Attention** : à la syntaxe des chemins : "monrepertoire/monfichier"  
pour windows : \ → \\ ou /  
pour linux : /

- C'est quoi un fichier tabulé
  - Autorisé : .csv, .tab, .txt, .blast, ... → format ASCII text
  - Pas autorisé : .xls, .xlsx, .ods

```
$ file data.tab
data.tab: ASCII text
```

paternity.csv

ID;Mother;Father
1;S1A2;S1A3
2;S1A2;S1A3
3;S1A2;S1A3
4;S1A2;S1A3
5;S1A2;S1A3
6;S1A2;S1A3
7;S1A2;S1A3
8;S1A2;S1A3
9;S1A2;S1A3
10;S1A2;S1A3

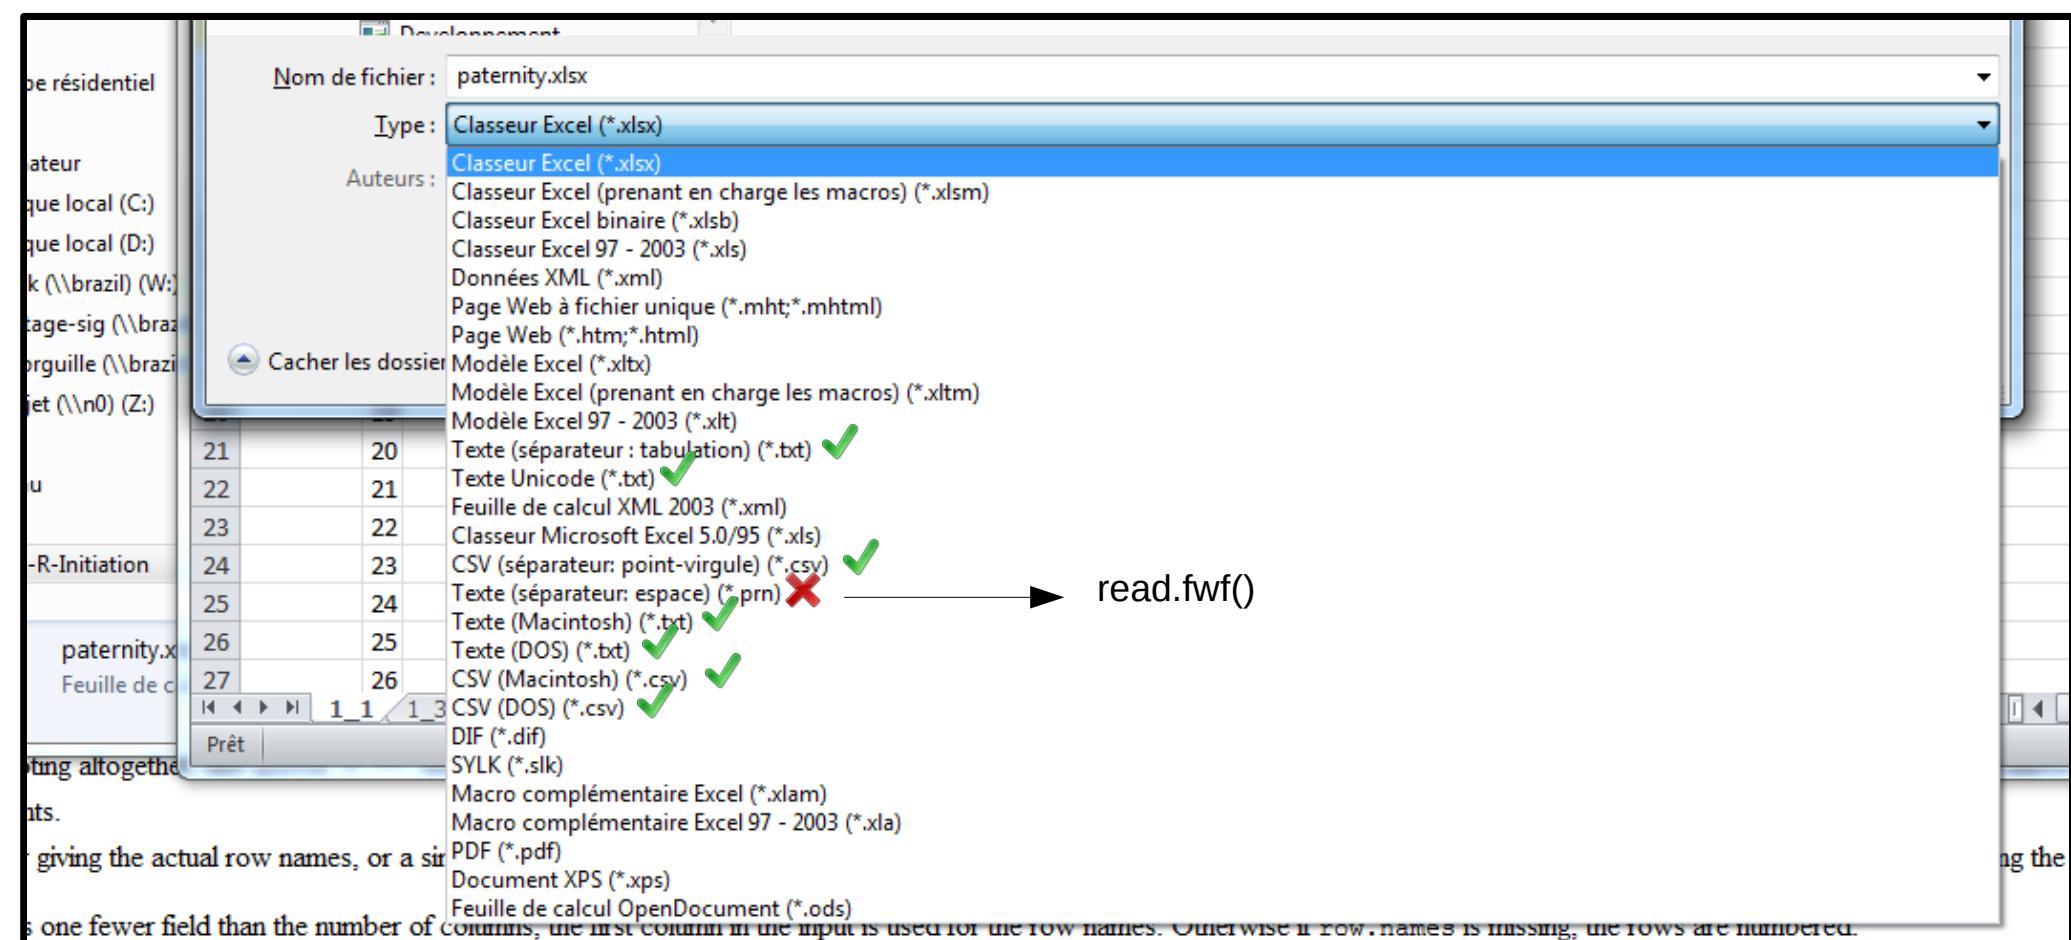
paternity.tab

ID	Mother	Father
1	S1A2	S1A3
2	S1A2	S1A3
3	S1A2	S1A3
4	S1A2	S1A3
5	S1A2	S1A3
6	S1A2	S1A3
7	S1A2	S1A3
8	S1A2	S1A3
9	S1A2	S1A3
10	S1A2	S1A3

paternity.txt

"ID"	"Mother"	"Fa
1	"S1A2"	"S1A3"
2	"S1A2"	"S1A3"
3	"S1A2"	"S1A3"
4	"S1A2"	"S1A3"
5	"S1A2"	"S1A3"
6	"S1A2"	"S1A3"
7	"S1A2"	"S1A3"
8	"S1A2"	"S1A3"
9	"S1A2"	"S1A3"
10	"S1A2"	"S1A3"

- Export depuis Microsoft®®®™ Office®®®™ Excel®®®™



→ `read.fwf()`

®®®™

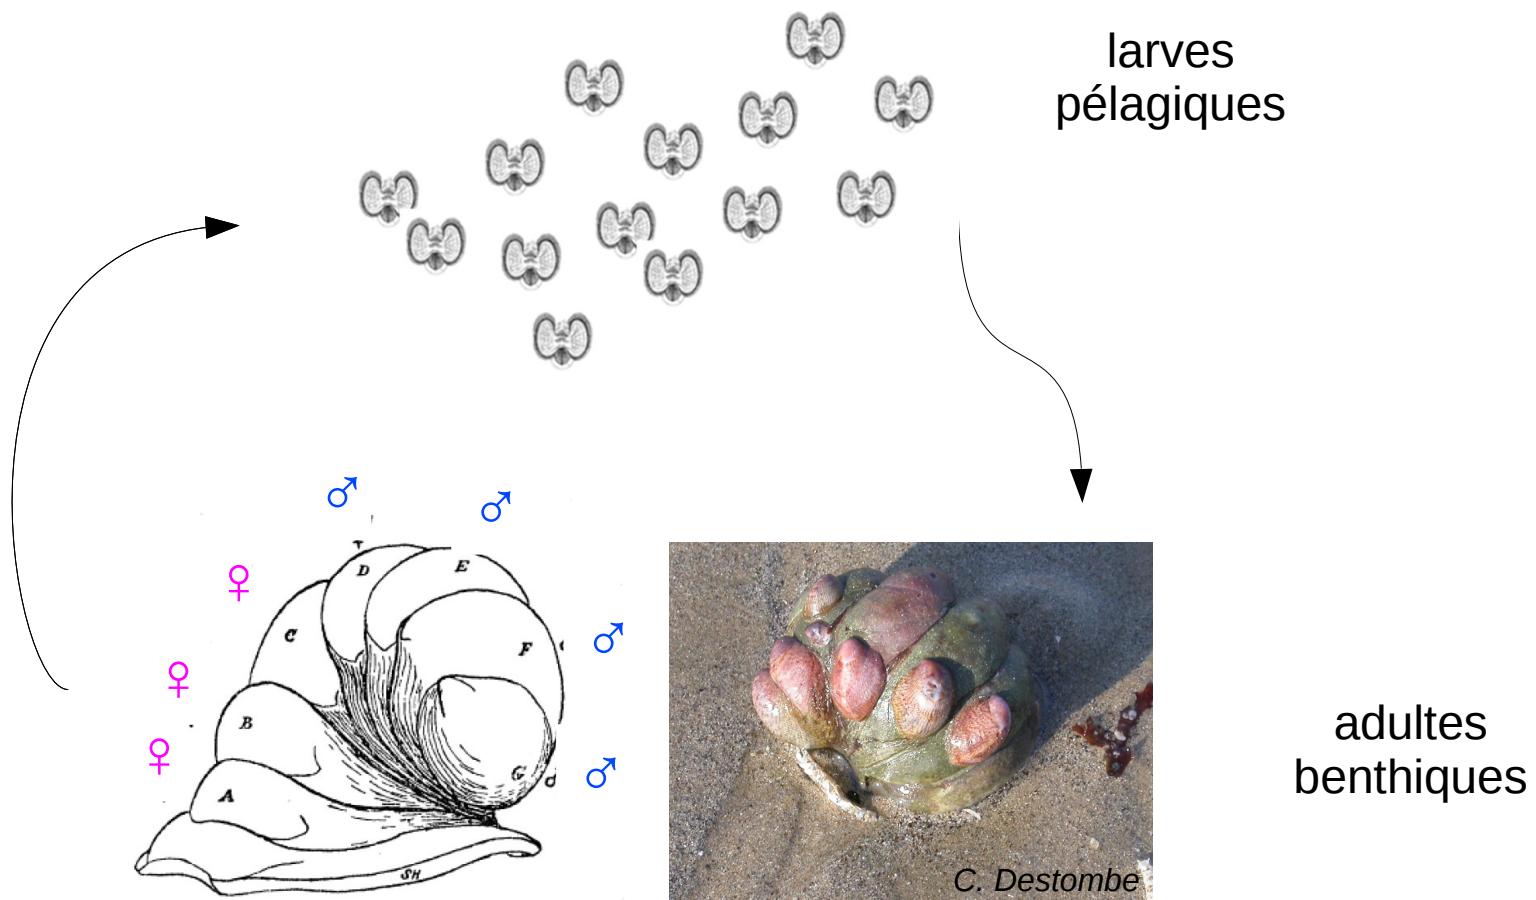
- Validation quand ça #%\$&!!
- Validation par nodepad++
- Symbole spéciaux → afficher tous les caractères



ID	Mother	Father
1	S1A2	S1A3
2	S1A2	S1A3
3	S1A2	S1A3
4	S1A2	S1A3
5	S1A2	S1A3
6	S1A2	S1A3
7	S1A2	S1A3
8	S1A2	S1A3
9	S1A2	S1A3
10	S1A2	S1A3

```
ID → Mother → Father LF
1 → S1A2 → S1A3 LF
2 → S1A2 → S1A3 LF
3 → S1A2 → S1A3 LF
4 → S1A2 → S1A3 LF
5 → S1A2 → S1A3 LF
6 → S1A2 · → S1A3 · LF
7 → S1A2 → S1A3 LF
8 → S1A2 → S1A3 LF
9 → S1A2 → S1A3 LF
10 → S1A2 · → S1A3 LF
```

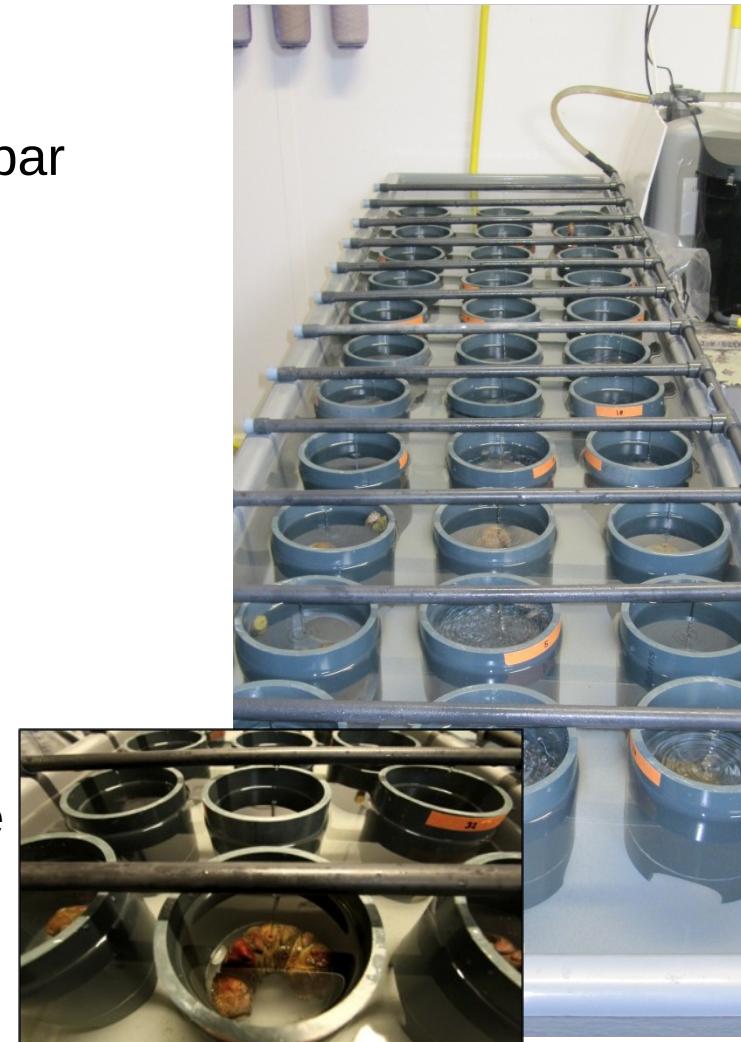
- Etude du succès reproducteur chez la crépidule



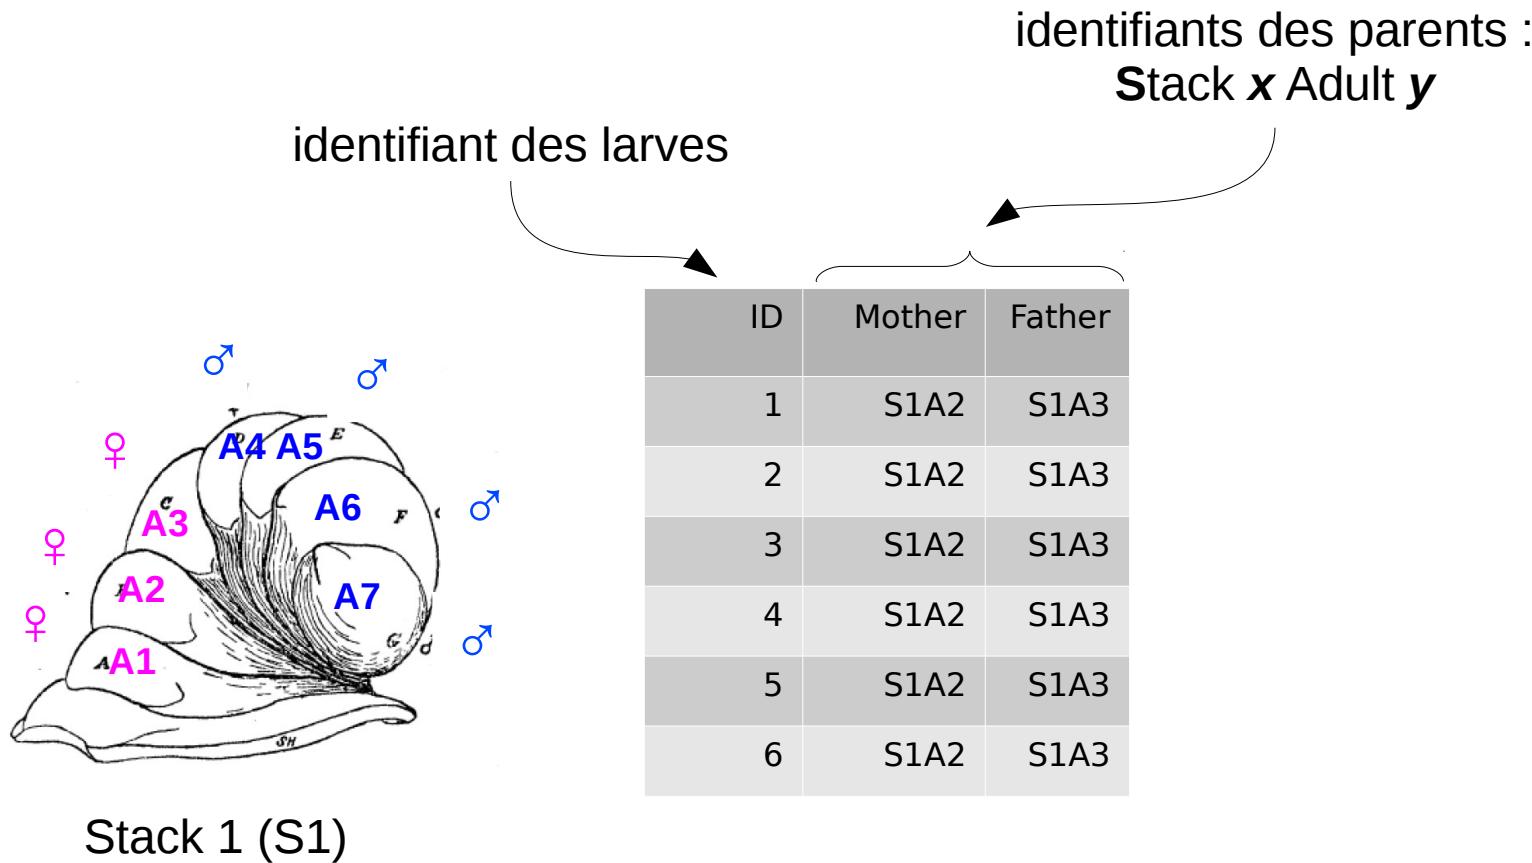
- Etude du succès reproducteur chez la crépidule

1. élevage des adultes
2. échantillonnage des larves émises par chaque chaîne d'individus
3. mesure des larves et génotypage
4. assignation génétique de parenté

- 
- système de reproduction
  - variance de succès reproducteur
  - dérive génétique
  - contributions parentales à la croissance larvaire
  - compromis croissance / reproduction
  - ...



- Les données : fichier excel “paternity.xlsx”



Rq: parfois pères inconnus : X1, X2

- Les données : fichier excel “offspring.xlsx”

nombreuses colonnes plus ou moins utiles accumulées au cours du travail ...

stack	clutch	label_clutch	day	ID	label_seq	label_plate	label_manue	plate	size	exp
1	1	1_1	0	1	AEB_P1-1	ind02	indiv01	P	404	Audrey
1	1	1_1	0	2	AEB_P1-1	ind03	indiv02	P	444	Audrey
1	1	1_1	0	3	AEB_P1-1	ind04	indiv03	P	424	Audrey
1	1	1_1	0	4	AEB_P1-1	ind05	indiv04	P	404	Audrey
1	1	1_1	0	5	AEB_P1-1	ind06	indiv05	P	404	Audrey
1	1	1_1	0	6	AEB_P1-1	ind07	indiv06	P	444	Audrey
1	1	1_1	0	7	AEB_P1-1	ind08	indiv07	P	384	Audrey
1	1	1_1	0	8	AEB_P1-1	ind09	indiv08	P	424	Audrey
1	1	1_1	0	9	AEB_P1-1	ind10	indiv09	P	424	Audrey
1	1	1_1	0	10	AEB_P1-1	ind11	indiv10	P	384	Audrey
1	1	1_1	0	11	AEB_P1-1	ind12	indiv11	P	444	Audrey

...

► identifiant des larves

- Etape 1 : formater les données sous Excel
  - attention aux espaces, aux accents, caractères spéciaux, etc.
  - enregistrer les différentes feuilles des classeurs “paternity.xlsx” et “offspring.xlsx” sous un format tabulé

- Etape 2 : commencer un script sous R-studio

```
# A script to analyse Crepidula paternity data
# Cours initiation à R - sept. 2012

# working directory
setwd("/projet/.../.../login/projet_crepidula/tmp/")
```

- Ctrl + Enter pour envoyer les commandes à R (ligne active ou sélection)
- Enregistrer ce script (e.g. "myscript.r") pour réutilisation ultérieure

- Etape 3 : création de tableaux de données
  - la fonction d'import sous R : `read.table()`

```
> ?read.table

> paternity = read.table("paternity.csv", header=TRUE, sep=";", quote="")

> paternity = read.table("paternity.tab", header=TRUE, sep="\t", quote="")

> paternity = read.table("paternity.txt", header=TRUE, sep="\t", quote="\\")

> head(paternity)
ID Mother Father
1 S1A2 S1A3
2 S1A2 S1A3
3 S1A2 S1A3
4 S1A2 S1A3
5 S1A2 S1A3
6 S1A2 S1A3
> View(paternity) # commande RStudio pour visualiser les données (sinon cliquer)
```

paternity.csv

ID;Mother;Father
1;S1A2;S1A3
2;S1A2;S1A3
3;S1A2;S1A3

paternity.tab

ID Mother Father
1 S1A2 S1A3
2 S1A2 S1A3
3 S1A2 S1A3

paternity.txt

"ID"	"Mother"	"Fa
1	"S1A2"	"S1A3"
2	"S1A2"	"S1A3"
3	"S1A2"	"S1A3"

- Etape 3 : création de tableaux de données
  - la fonction d'import sous R : `read.table()`

```
# A script to analyse Crepidula paternity data
# Cours initiation à R - sept. 2012

# working directory
setwd("/projet/....../login/projet_crepidula/tmp/")

##### import raw data
# offspring
offspring <- read.table("offspring.txt", header=T, sep="\t")

# parents: 3 files
parents1 <- read.table("stack1.txt", header=T, sep="\t")
parents2 <- read.table("stack2.txt", header=T, sep="\t")
parents25 <- read.table("stack25.txt", header=T, sep="\t")
```

- Quand R essaye de communiquer : les messages d'erreur

```
> setwd("/projet/....../login/projet_crepidule/tmp/")
Error in setwd("/projet/....../login/projet_crepidule/tmp/") :
  cannot change working directory
```

```
> offspring <- read.table("offspring.txt", header=T, sep="\t")
Error in make.names(col.names, unique = TRUE) :
  invalid multibyte string 11
```

- Autre fonction d'import sous R : scan( )

```
> ?scan
```

## Manipulation d'objets plus complexes

- Les modes

- numérique : 1 -1 0.5 2.1e23
- caractère : "a" "Hello World" 'toto' "cas \"pas simple\""
- logique : TRUE / FALSE  

```
> 1 == 1
[1] TRUE
```
- complexe : > complex(real = 0, imaginary = 1)  

```
[1] 0+1i
```

- Pour obtenir le mode : mode()

```
> mode(a)
[1] "numeric"
> mode(A)
[1] "character"
> mode(1==1)
[1] "logical"
```

- Les classes (ou types)

- vecteur (vector) : suite d'éléments une dimension
- matrice (matrix) : tableau à 2 dimensions
- tableau (array) : tableau à k dimensions
- tableau de données (data.frame) :  
ensemble de vecteurs de même longueur
- liste (list) : liste d'objets
- facteur (factor)  
suite d'éléments catégoriels avec niveaux
- séries temporelles (ts) : fréquence, dates ...

Plusieurs modes autorisés  
dans le même objet ?



- vecteur (vector) : suite d'éléments une dimension
  - 1 mode autorisé dans un même objet

```
> myvector = c(1,3,5,7,9)
> myvector
[1] 1 3 5 7 9

> length(myvector)
[1] 5

> myvector2 = c(myvector,2,4,6,8)
> myvector2
[1] 1 3 5 7 9 2 4 6 8

> myvector2 - 1
[1] 0 2 4 6 8 1 3 5 7

>
>
> myvector2 - myvector
[1] 0 0 0 0 0 1 1 1 1
Message d'avertissement :
In y - x :
  la taille d'un objet plus long n'est pas multiple de la taille d'un objet plus court
```

- Générateur de vecteurs

```

> 1:25
[1] 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25

> seq(1,10,by=0.5)
[1] 1.0 1.5 2.0 2.5 3.0 3.5 4.0 4.5 5.0 5.5 6.0 6.5 7.0 7.5 8.0 8.5 9.0 9.5
[19] 10.0

> seq(1,25,2)
[1] 1 3 5 7 9 11 13 15 17 19 21 23 25

> rep(1,25)
[1] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1

> sequence(4:5)
[1] 1 2 3 4 1 2 3 4 5

>
> rnorm(25, mean=0, sd=1)
[1] 1.861223234 0.179097312 0.193908771 0.447167513 0.490801348 1.718215675
[7] -0.008796725 1.808822710 0.055496719 -0.761208517 -0.504335108 -0.824040103
[13] -1.471801732 2.003031214 1.313190462 1.505939057 1.098118465 -0.695082609
[19] -0.338180962 -0.116440754 -1.242136683 -1.048167354 1.492289109 1.432021299
[25] 1.494668508

> # quelques autres : rexp, rgamma, rpois, ...

```

- Accéder aux valeurs d'un vecteur

```
> myvector = 1:25
> myvector
[1] 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25

> myvector[8]
[1] 8

> myvector[-8]
[1] 1 2 3 4 5 6 7 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25

> myvector[2:4]
[1] 2 3 4

> myvector[seq(1,25,by=2)]
[1] 1 3 5 7 9 11 13 15 17 19 21 23 25

> myvector[10] = 100

> myvector > 10
[1] FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE TRUE TRUE TRUE
[13] TRUE TRUE
[25] TRUE

> myvector[myvector > 10]
[1] 100 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25
```



Contrairement aux autres langages de développement, les indices de tableaux commence à 1

- matrice (**matrix**) : tableau à 2 dimensions
  - 1 mode autorisé dans un même objet

```
> matrix(data=1:6, nrow=2, ncol=3)
      [,1] [,2] [,3]
[1,]    1    3    5
[2,]    2    4    6

> matrix(1:6, 2, 3, byrow=TRUE)
      [,1] [,2] [,3]
[1,]    1    2    3
[2,]    4    5    6

> cbind(c(1,2),c(3,4),c(5,6))
      [,1] [,2] [,3]
[1,]    1    3    5
[2,]    2    4    6

> rbind(c(1,2,3),c(4,5,6))
      [,1] [,2] [,3]
[1,]    1    2    3
[2,]    4    5    6
```

- matrice (`matrix`) : tableau à 2 dimensions
  - 1 mode autorisé dans un même objet

```
> dim(mymatrix)
[1] 2 3

> ncol(mymatrix)
[1] 3

> nrow(mymatrix)
[1] 2

> mymatrix = 1:12           # nous avons pour le moment un vector

> mymatrix
[1]  1  2  3  4  5  6  7  8  9 10 11 12

> dim(mymatrix)
NULL

> dim(mymatrix) = c(4,3)    # ici, nous forcons pour creer une matrix

> mymatrix
     [,1] [,2] [,3]
[1,]    1    5    9
[2,]    2    6   10
[3,]    3    7   11
[4,]    4    8   12
```

- Accéder aux valeurs d'une matrice

```
> mymatrix = matrix(data=1:12, nrow=4, ncol=3)
> mymatrix
     [,1] [,2] [,3]
[1,]    1    5    9
[2,]    2    6   10
[3,]    3    7   11
[4,]    4    8   12

> mymatrix[3,2]
[1] 7

> mymatrix[2,]
[1] 2 6 10

> mymatrix[,2]
[1] 5 6 7 8

> mymatrix[3:4,1:2]
     [,1] [,2]
[1,]    3    7
[2,]    4    8
```

- Accéder aux valeurs d'une matrice

```
> mymatrix
 [,1] [,2] [,3]
[1,]    1    5    9
[2,]    2    6   10
[3,]    3    7   11
[4,]    4    8   12

> dimnames(mymatrix)
NULL

> colnames(mymatrix) = c("condition1", "condition2", "condition3")
> rownames(mymatrix) = c("sample1", "sample2", "sample3", "sample4")
> dimnames(mymatrix)
[[1]]
[1] "sample1" "sample2" "sample3" "sample4"

[[2]]
[1] "condition1" "condition2" "condition3"

> mymatrix
      condition1 condition2 condition3
sample1         1          5          9
sample2         2          6         10
sample3         3          7         11
sample4         4          8         12

> mymatrix["sample2", "condition3"]
[1] 10
```

- Accéder aux valeurs d'une matrice

```
> mymatrix
     [,1] [,2] [,3]
[1,]    1    5    9
[2,]    2    6   10
[3,]    3    7   11
[4,]    4    8   12

> mymatrix[mymatrix >= 10]
[1] 10 11 12

> mymatrix[mymatrix >= 10] = NA
     [,1] [,2] [,3]
[1,]    1    5    9
[2,]    2    6   NA
[3,]    3    7   NA
[4,]    4    8   NA
```

- tableau (array) : tableau à k dimensions
  - 1 mode autorisé dans un même objet

```
> myarray = array(data=c(11,12,13,14,15,16,21,22,23,24,25,26,31,32,33,34,35,36), dim=c(3,2,3))
> myarray
, , 1

[1,] [,1] [,2]
[1,]    11   14
[2,]    12   15
[3,]    13   16

, , 2

[1,] [,1] [,2]
[1,]    21   24
[2,]    22   25
[3,]    23   26

, , 3

[1,] [,1] [,2]
[1,]    31   34
[2,]    32   35
[3,]    33   36

> myarray[1,2,3]
[1] 34
```

- tableau de données (`data.frame`) : ensemble de vecteurs de même longueur
  - plusieurs modes autorisés dans un même objet

```
> array1 = c(-1.5585350, -0.5669521, -0.7483982, -0.5685524, 0.5566560, -0.3465147)
> array2 = c(-0.7348447, -1.1037727, -0.3216453, 0.1248720, -0.6403694, -1.0225939)
> gene = c("typ1", "droML", "furA", "sufB", "rpo42", "rrr")

> mydataframe = data.frame(array1, array2, gene)
> mydataframe
   array1     array2   gene
1 -1.5585350 -0.7348447 typ1
2 -0.5669521 -1.1037727 droML
3 -0.7483982 -0.3216453 furA
4 -0.5685524  0.1248720 sufB
...
.

> mydataframe = cbind(mydataframe, core=c(TRUE, TRUE, FALSE, FALSE, TRUE, FALSE))
> mydataframe
   array1     array2   gene  core
1 -1.5585350 -0.7348447 typ1  TRUE
2 -0.5669521 -1.1037727 droML TRUE
3 -0.7483982 -0.3216453 furA FALSE
4 -0.5685524  0.1248720 sufB FALSE
...
.

> mydataframe = cbind(mydataframe, rank=c(2, 1, 4, 3, 5))
Erreur dans data.frame(..., check.names = FALSE) :
  les arguments impliquent des nombres de lignes différents : 6, 5
```

- tableau de données (`data.frame`) : ensemble de vecteurs de même longueur

```
> mydataframe
   array1    array2   gene core
1 -1.5585350 -0.7348447 typ1 TRUE
2 -0.5669521 -1.1037727 droML TRUE
3 -0.7483982 -0.3216453 furA FALSE
4 -0.5685524  0.1248720 sufB FALSE
5  0.5566560 -0.6403694 rpo42 TRUE
6 -0.3465147 -1.0225939 rrr FALSE

> mydataframe[4, 2]
[1] 0.124872

> mydataframe[4, "array2"]
[1] 0.124872

> mydataframe$array2[4]
[1] 0.124872

> mycolumn = "array2"
> mydataframe[[mycolumn]][4]
[1] 0.124872

> mydataframe["array2"][4]
Erreur dans ` [.data.frame` (mydataframe["array2"], 4) : undefined columns selected
> mydataframe["array2"][4, ]
[1] 0.124872
```

- Retour au jeu de données Crepidula
  - fusionner les 3 data.frames contenant les parents

```
# parents: 3 files
parents1 <- read.table("stack1.txt", header=T, sep="\t")
parents2 <- read.table("stack2.txt", header=T, sep="\t")
parents25 <- read.table("stack25.txt", header=T, sep="\t")

# group all parentage data within one single dataframe
parents = rbind(parents1, parents2, parents25)
```

- Retour au jeu de données Crepidula
  - sélectionner les champs utiles du tableau offspring

```
# sélectionne certaines données du tableau offspring :  
# uniquement les champs ID, day, size  
temp <- subset(offspring, select=c(stack, ID, size))
```

- former un seul tableau contenant toutes les informations (e.g. taille des larves et identité des parents)

```
# combine les jeux de données en se basant sur la seule colonne en  
# commun aux deux tableaux : ID  
data <- merge(temp, parents)
```

- Retour au jeu de données Crepidula
  - vérifications

```
> dim(offspring)
```

```
[1] 1221 11
```

```
> dim(parents)
```

```
[1] 959 3
```

```
> dim(data)
```

```
[1] 959 5
```



La fonction merge() n'a conservé que les individus (ID) présents à la fois dans le tableau offspring et le tableau parents

```
> head(data)
```

	ID	stack	size	Mother	Father
1	1	1	404.0	S1A2	S1A3
2	2	1	444.4	S1A2	S1A3
3	3	1	424.2	S1A2	S1A3
4	4	1	404.0	S1A2	S1A3
5	5	1	404.0	S1A2	S1A3
6	6	1	444.4	S1A2	S1A3

```
> data$ID
```

- liste (list) : liste d'objets
  - plusieurs objets autorisés dans un même objet

```
> mylist = list(a=a,A=A,myvector=myvector,mymatrix=mymatrix,myarray=myarray)
> mylist
$a
[1] 5

$A
[1] "Hello World!"

$myvector
[1]  1  2  3  4  5  6  7  8  9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25

$mymatrix
      condition1 condition2 condition3
sample1       1       5       9
sample2       2       6      10
sample3       3       7      11
sample4       4       8      12

$myarray
, , 1

      [,1] [,2]
[1,]   11   14
[2,]   12   15
[3,]   13   16

, , 2

      [,1] [,2]
[1,]   21   24
...

> mylist$mydataframe = mydataframe
```

- liste (list) : liste d'objets

```
> mylist
$a
[1] 5

$A
[1] "Hello World!"

$myvector
 [1] 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25

$mymatrix
      condition1 condition2 condition3
sample1          1          5          9
sample2          2          6         10
...
...

> names(mylist)
[1] "a"           "A"           "myvector"     "mymatrix"    "myarray"     "mydataframe"

> mylist[[3]]
[1] 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25

> mylist[["myvector"]]
[1] 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25

> mylist[3]
$myvector
[1] 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25
```

- facteur (factor) : suite d'éléments catégoriels avec niveaux
  - 1 mode autorisé dans un même objet

```
> dataVector = 1:10
> dataVector
[1] 1 2 3 4 5 6 7 8 9 10
```

```
> sampleVector = sample(dataVector, 10,
replace = TRUE)
> sampleVector
[1] 5 6 5 4 9 8 10 1 10 3
```

```
> table(sampleVector)
sampleVector
 1 3 4 5 6 8 9 10
 1 1 1 2 1 1 1 2
```

```
> sampleVector = factor(sampleVector,
levels = 1:10)
```

```
> dataFactor = as.factor(1:10)
> dataFactor
[1] 1 2 3 4 5 6 7 8 9 10
Levels: 1 2 3 4 5 6 7 8 9 10
```

```
> sampleFactor = sample(dataFactor, 10,
replace = TRUE)
> sampleFactor
[1] 5 6 5 4 9 8 10 1 10 3
Levels: 1 2 3 4 5 6 7 8 9 10
```

```
> table(sampleFactor)
sampleFactor
 1 2 3 4 5 6 7 8 9 10
 1 0 1 1 2 1 0 1 1 2
```

- facteur (factor) : suite d'éléments catégoriels avec niveaux

```
> mydataframe$gene  
[1] typ1  droML furA  sufB  rpo42 rrr  
Levels: droML furA rpo42 rrr sufB typ1
```

```
> class(mydataframe$gene)  
[1] "factor"
```

```
> c(mydataframe$gene, "yo")  
[1] "6"  "1"  "2"  "5"  "3"  "4"  "yo"
```

```
> c(as.vector(mydataframe$gene), "yo")  
[1] "typ1"  "droML" "furA"  "sufB"  "rpo42" "rrr"   "yo"
```



```
> options(stringsAsFactors = FALSE)  
  
> mydataframe$gene = c("typ1", "droML", "furA", "sufB", "rpo42", "rrr")  
> mydataframe$gene  
[1] "typ1"  "droML" "furA"  "sufB"  "rpo42" "rrr"  
  
> class(mydataframe$gene)  
[1] "character"  
  
> c(mydataframe$gene, "yo")  
[1] "typ1"  "droML" "furA"  "sufB"  "rpo42" "rrr"   "yo"
```

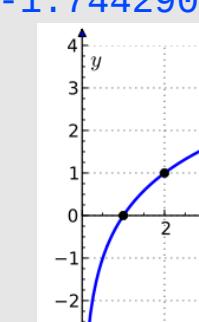
- ## • Les valeurs manquantes :

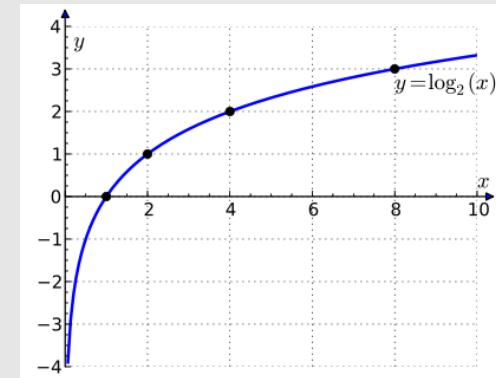
```
> c(1.2604103,1.4802003,NA,1.6124621,1.6718345,0.5794688,-1.7442904)
[1] 1.2604103 1.4802003 NA 1.6124621 1.6718345 0.5794688 -1.7442904

> log(0)
[1] -Inf

> log(1e-1000) - log(1e-1000)
[1] NaN

> mydataframe$annotation
NULL
```





- Les fonctions de test (return TRUE/FALSE)
    - Pour NA → `is.na()`
    - Pour Inf et -Inf → `is.infinite()` (à l'opposé : `is.finite()`)
    - Pour NaN → `is.nan()`
    - Pour NULL → `is.null`

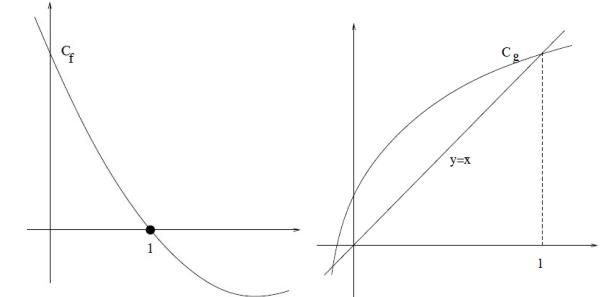
# Fonctions mathématiques

- Les opérateurs arithmétiques

- + - \* / : les classiques
- ^ : puissance
- %% : modulo
- %/% : division entière

### • Les opérateurs de comparaison

- `==` : égalité      `!=` : différence
- `> < <= >=`



```
> (1 - 0.3) == 0.7
```

```
[1] TRUE
```

```
> (1.1 - 0.4) == 0.7
```

```
[1] FALSE
```

```
> all.equal(1.1 - 0.4, 0.7)
```

```
[1] TRUE
```

```
> isTRUE(all.equal(1.1 - 0.4, 0.7))
```

```
[1] TRUE
```



Il faut se méfier des erreurs numériques dues aux calculs numériques sur l'ordinateur (le epsilon machine).

`all.equal()` compare l'égalité approximative avec un seuil de tolérance dicté par la machine

\*

\* source [http://www-irma.u-strasbg.fr/~salmon/polyanum\\_salmon.pdf](http://www-irma.u-strasbg.fr/~salmon/polyanum_salmon.pdf)

### Analyse Numérique

$$x = \pm 0.a_1 \dots a_N.b^E, \quad \begin{cases} -Tu''(x) = f(x) \quad \forall x \in ]0, 1[ \\ u(0) = 0. \\ u(1) = 0. \end{cases}$$

#### 0.2 Pourquoi un ordinateur fait-il des calculs faux ?

Tout simplement parce qu'il ne connaît qu'un nombre fini de nombres ! Par exemple ceux qui possèdent un nombre fini donné de chiffres non nuls après la virgule, or ce n'est pas le cas de  $1/3$  ou de  $\sqrt{2}$  qui ont un nombre infini de chiffres non nuls après la virgule.

[...]

$$\frac{0p \dots 1-d}{q} p^d p \text{ où } q^l p \sum_d = u$$

$x = x - \frac{f(x)}{\alpha} = g(x), \alpha \neq 0$

$$\frac{|x - Ar(x)|}{|x|} \leq \underbrace{\frac{b}{2} b^{-N}}_{\text{précision machine}} \quad x = \sum_{i=-\infty}^p d_i b^i \text{ noté } \overline{d_p d_{p-1} \dots d_0, d_{-1} \dots d_{-q} \dots}$$

#### 0.2.3 Erreurs

La première source d'erreurs dans les calculs faits par un ordinateur provient donc d'abord des erreurs d'arrondi sur les données. Puis des opérations effectuées sur les réels en virgule flottante. Nous ne nous étendrons pas sur ce sujet (voir TAN licence) mais il faut être conscient que certaines opérations, telles la soustraction de deux réels voisins par exemple, peut être une source d'erreurs non négligeables !

Exemple

Soit  $x = 0, 124322.104$  et  $y = 0, 123171.104$ . Le calcul de  $x - y$  sur une machine à 4 chiffres significatifs donne  $Ar(x) - Ar(y) = 0, 1243.104 - 0, 1231.104 = 0, 11.102$ , il ne reste alors plus que deux chiffres significatifs ! (c'est ce que l'on appelle l'extinction de chiffres).

- Les opérateurs logiques

- $\text{!}x$  : NON logique
- $x \& y$  : ET logique
- $x | y$  : OU logique

```
> mylogique1 = c(TRUE, TRUE, FALSE)
> mylogique2 = c(FALSE, TRUE, TRUE)

> !mylogique1
[1] FALSE FALSE  TRUE

> mylogique1&mylogique2
[1] FALSE  TRUE FALSE

> mylogique1|mylogique2
[1] TRUE TRUE TRUE

> mydataframe[mydataframe$array1 < 0 & mydataframe$array2 < 0 & mydataframe$core, ]
      array1    array2   gene core
1 -1.5585350 -0.7348447 typ1 TRUE
2 -0.5669521 -1.1037727 droML TRUE
```

- Les fonctions simples

- `sum(x)`, `prod(x)`, `min(x)`, `max(x)`
- `which.min(x)`, `which.max(x)` : indice de la valeur min/max

```
> sum(c(1,3,5))
[1] 9
> prod(c(1,3,5))
[1] 15
> sum(mymatrix)
[1] 78
> prod(mymatrix)
[1] 479001600

> max(sampleVector)
[1] 10
> which(sampleVector == max(sampleVector))
[1] 7 9

> sum(c(1,NA,5))
[1] NA
> sum(c(1,NA,5), na.rm = TRUE)
[1] 6
```



Beaucoup de fonctions ont cette option

- Les fonctions simples

- `rev(x)`
- `sort(x)`
- `choose(n, k)` : combinatoire de k élément parmi n
- `sample(x, n)` : tirage aléatoire sans remise de n éléments parmi x

```
> sampleVector
[1] 5 6 5 4 9 8 10 1 10 3
> rev(sampleVector)
[1] 3 10 1 10 8 9 4 5 6 5
> sort(sampleVector)
[1] 1 3 4 5 5 6 8 9 10 10
> sort(sampleVector, decreasing=TRUE)
[1] 10 10 9 8 6 5 5 4 3 1

> choose(100,10)
[1] 1.731031e+13

> sample(1:100, 10)
[1] 26 74 43 96 97 29 90 85 60 17
```

- Les fonctions "statistiques"

- `mean(x)` → moyenne, `median(x)` → médiane
- `var(x)` → variance
- `cor(x,y)` → corrélation
- `cov(x,y)` → covariance

$$\sigma_{XY} = \text{cov}(X, Y) = \sum_{i=1}^n \sum_{j=1}^m x_i y_j \mathbb{P}(X = x_i \text{ et } Y = y_j) - \mathbb{E}[X]\mathbb{E}[Y].$$

```
> sampleVector
[1] 5 6 5 4 9 8 10 1 10 3

> mean(sampleVector)
[1] 6.1
> median(sampleVector)
[1] 5.5
> var(sampleVector)
[1] 9.433333

> cor(sampleVector, sort(sampleVector))
[1] 0.03415783
> cor(sort(sampleVector), sort(sampleVector, decreasing=TRUE))
[1] -0.9434629

> cov(sampleVector, sort(sampleVector))
[1] 0.3222222
> cov(sort(sampleVector), sort(sampleVector, decreasing=TRUE))
[1] -8.9
```

- Les fonctions matricielles

- `x%*%y` : produit de deux matrices
- `t(x)` : transposée de `x`
- `diag(x)` : extrait la diagonale d'une matrice `x`

```
> mymatrix = matrix(1:9, 3, 3)
> mymatrix
     [,1] [,2] [,3]
[1,]    1    4    7
[2,]    2    5    8
[3,]    3    6    9
> mymatrix %*% mymatrix
     [,1] [,2] [,3]
[1,]   30   66  102
[2,]   36   81  126
[3,]   42   96  150
> diag(mymatrix)
[1] 1 5 9
> t(mymatrix)
     [,1] [,2] [,3]
[1,]    1    2    3
[2,]    4    5    6
[3,]    7    8    9
```

- %in%

```
> 12 %in% data$ID
[1] TRUE

> 1324 %in% data$ID
[1] FALSE

> 1324 %in% data
[1] FALSE
```

- apply

```
> tapply(data$size, data$stack, mean)
      1       2       25
429.0630 405.8439      NA

> tapply(data$size, data$stack, mean, na.rm=T)
      1       2       25
429.0630 405.8439 404.6942
```

1) Ajouter au jeu de données “data” une colonne “pair” contenant un identifiant par couple de parents (ex: S1A1\_S1A2).

→ utiliser la fonction `paste()`

2) Combien de larves produites par le couple S1A2\_S1A3 ont-elles été mesurées ?

→ utiliser la fonction `length()`

3) Calculer la taille moyenne des larves du couple S1A2\_S1A3

4) Obtenir automatiquement ce résultat pour l'ensemble des couples

→ en utilisant la fonction `tapply()`

→ puis en utilisant la fonction `aggregate()`

5) Même chose (avec la fonction `aggregate()`), mais en ayant préalablement sous-sélectionné seulement les chaines 1 et 2 (stacks)

→ utiliser la fonction “`subset()`”

6) Obtenir un tableau contenant le nombre et la taille moyenne des larves pour chaque couple des chaines 1 et 2

→ combiner les fonctions `subset()`, `aggregate()`, et `tapply()`

```
# ajouter une colonne "pair"
data$pair <- paste(data$Mother,data$Father,sep="_")

# nombre de larves produites par le couple S1_A2_S1_A3
length(data$size[data$pair=="S1A2_S1A3"])

# moyenne de la taille des larves produites par ce couple
mean(data$size[data$pair=="S1A2_S1A3"])

# ou encore
with(data[data$pair=="S1A2_S1A3", ],
     mean(size)
   )

# moyenne pour chaque couple (avec la fonction tapply)
tapply(data$size,data$pair,mean)
```

```
# avec la fonction "aggregate"  
aggregate(data$size,  
          by=list(data$Mother,data$Father),  
          FUN=mean)  
  
# même chose en conservant les noms de colonnes "Mother" et "Father"  
aggregate(data$size,  
          by=list(Mother=data$Mother,Father=data$Father),  
          FUN=mean)  
  
# plus compact  
aggregate(size~Mother+Father,data,mean)
```

```
# mêmes calculs effectués seulement pour certaines chaînes de crépidules  
  
stack_list <- c(1,2)  
sub_data <- subset(data,data$stack %in% stack_list)  
summary <- aggregate(size~Mother+Father, sub_data, mean)  
  
# Finalement, si on veut ajouter les tailles d'échantillons  
summary$n <- tapply(sub_data$size, sub_data$pair, length)
```

# Programmation

- If / else if / else

```
> up = 1; down = -1
> a = 0.5

> if (a > up) {
+   b="ok";
+ } else if (a < down) {
+   b="bof";
+ } else {
+   b="null";
+ }

> b
[1] "null"
```

- for

```
for(i in values){  
  ... do something ...  
}
```

```
> for (i in seq(1:5)) { print (i) }  
[1] 1  
[1] 2  
[1] 3  
[1] 4  
[1] 5  
  
> for (num_line in 1:nrow(mymatrix)) {  
+   if (num_line %% 10) { ... } }  
  
> datas = list()  
> for (infile_i in infiles) {  
+   datas[[infile_i]] = read.table(infile_i, header=TRUE, check.names=FALSE)  
+ }
```

- while

```
while(condition){  
    ... do something ...  
}
```

```
> j=1  
> while (j < 5) { print(j); j=j+1 }  
[1] 1  
[1] 2  
[1] 3  
[1] 4  
[1] 5
```



Attention aux boucles infinies

```
while (j < 5) { print (j); }
```

# Fonctions propre à R pour la manipulation de tableaux

- `apply` : apply fonction over array margins

```
> head(mymatrix)
      [,1]      [,2]      [,3]      [,4]      [,5]
[1,]  0.57177836 -0.09623617 -1.2877098 -0.999702657 -1.83084206
[2,]  0.36411961 -0.69660756  0.3213590 -0.065069318 -0.09920370
[3,] -0.69590786  0.20113220  1.4770141  0.198917245 -0.08979680

> dim(mymatrix)
[1] 100   5

> apply(mymatrix, 1, mean)
[1] -0.728542456 -0.035080387  0.218271782  0.158465563  0.257838960  0.327600
[16]  0.282106984  0.269398490  0.093404380 -0.230242816  0.653728937 -0.37 [...]
[91]  0.447504533 -0.905960081 -0.542304096  0.175122985 -0.510900002 -0.074437

> apply(mymatrix, 2, mean)
[1] -0.088757464  0.017911582  0.097586186 -0.008795336 -0.019285733
```

- lapply → sapply → vapply : Apply a Function over a List or Vector

```
> ?lapply
```

Exemple graph par fichier infiles

- mapply : Apply a Function to Multiple List or Vector Arguments

```
> ?mapply
```

- tapply : Apply a Function Over a Ragged Array

```
> ?tapply
```

- apply avec une fonction maison

```
> threshold = function(x, up = 0, down = 0) {  
+   if (mean(x) > up) {  
+     return("ok");  
+   } else if (mean(x) < down) {  
+     return("bof");  
+   } else {  
+     return("null");  
+   }  
+ }  
  
> threshold(1.5)  
[1] "ok"  
> threshold(1.5, 2, -2)  
[1] "null"  
  
> apply(mymatrix, 1, threshold, 1, -1)  
[1] "ok"    "null"  
[20] "null"  
[39] "null"  "bof"   "null"  
[58] "null"  "null"  "null"  "null"  "null"  "ok"   "ok"   "null"  "null"  "null"  "null"  "null"  
[77] "null"  
[96] "null"  "null"  "null"  "null"  "ok"
```

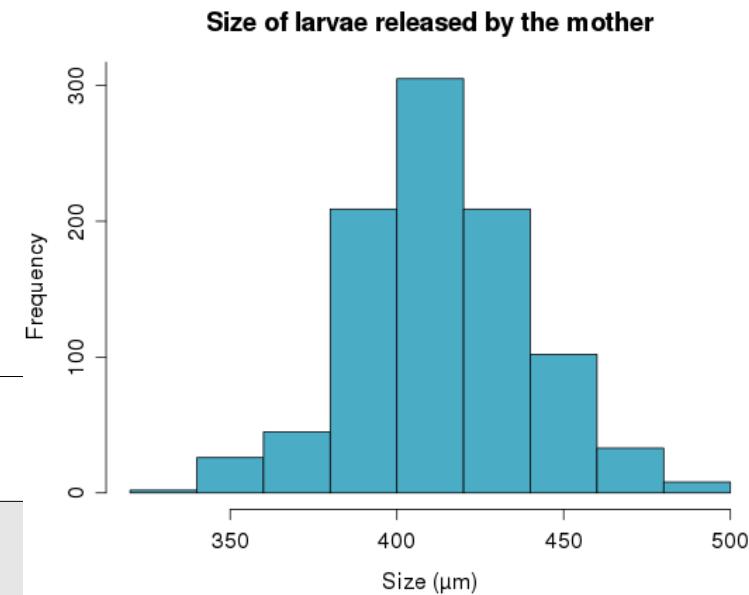
# Graphiques

- Quelques exemples : histograms, boxplots, scatterplots

```
### Exploration graphique
```

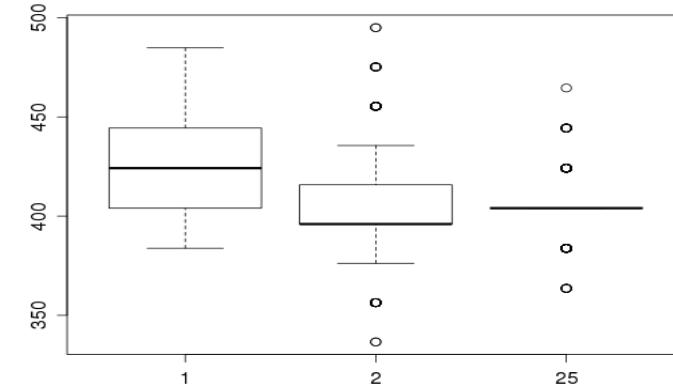
```
#histogramme de fréquences de taille pour toutes les larves  
hist(data$size)
```

```
# quelques améliorations graphiques  
col1 <- rgb(75, 172, 198, maxColorValue=255)  
hist(data$size, yaxp=c(0, 1000, 10), col=col1,  
     main="Size of larvae released by the mother",  
     xlab="Size ( $\mu$ m)")
```

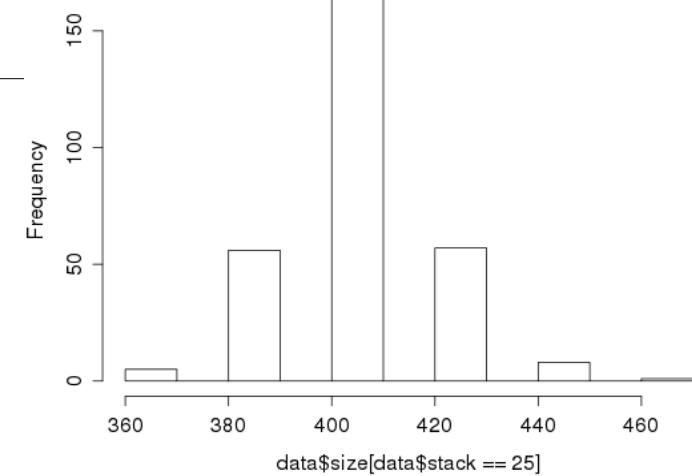


```
> help(par)
```

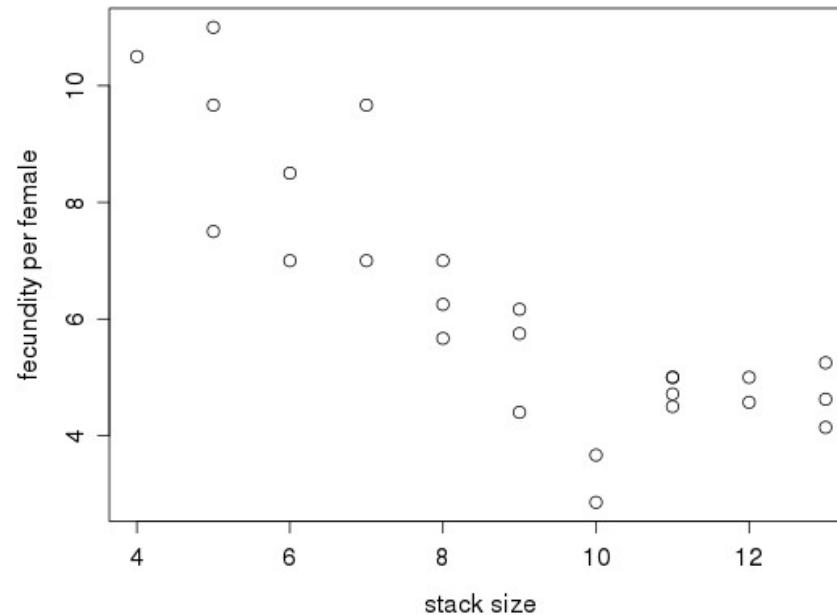
```
# Différences de tailles larvaires émises par les différentes mères ?  
# Différents pères ? # Différentes chaînes ?  
boxplot(size~Mother,data)  
boxplot(size~Father,data)  
boxplot(size~stack,data)
```



```
# Pour comprendre le boxplot bizarre de la chaîne 25  
hist(data$size[data$stack==25]))
```

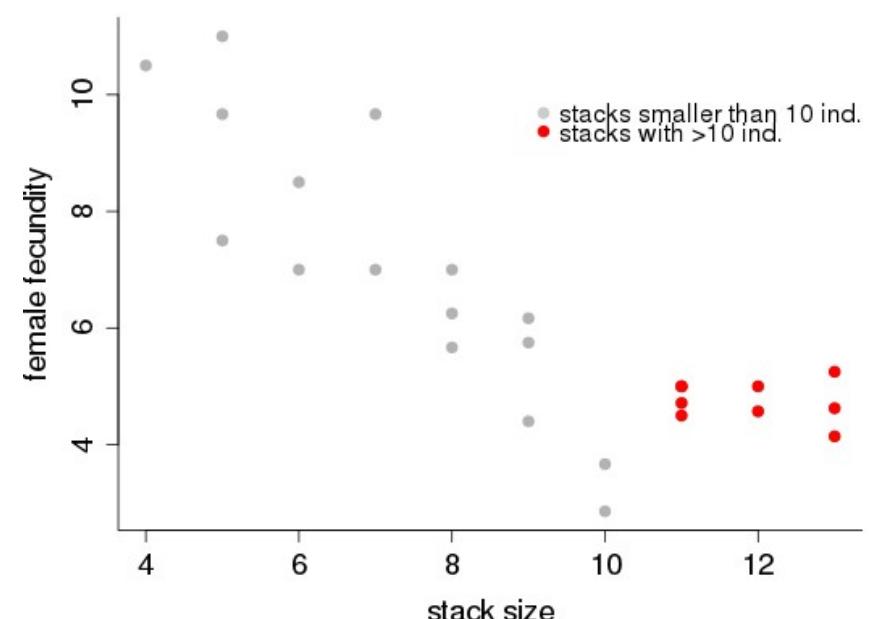
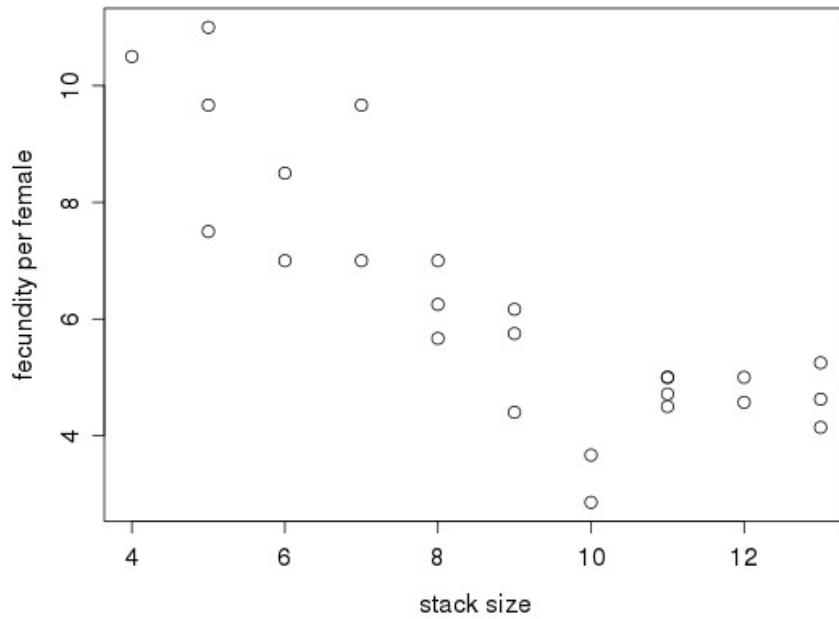


```
# Fécondité des femelles au sein des différentes chaînes de crépidules  
  
data2 <- read.table("data/fecundity.txt", sep="\t", header=T)  
plot(nclutch/nfemales~stack_size, data=data2,  
     xlab='stack size', ylab='fecundity per female')
```



```
# Fécondité des femelles au sein des différentes chaînes de crépidules
```

```
data2 <- read.table("data/fecundity.txt", sep="\t", header=T)
plot(nclutch/nfemales~stack_size, data=data2,
     xlab='stack size', ylab='fecundity per female')
```



```
# Fécondité des femelles au sein des différentes chaines de crépidules

plot(nclutch/nfemales~stack_size,data2,
      xlab="stack size",
      ylab="female fecundity",
      pch=16,
      col=grey(0.7),
      cex.lab=1.2,
      cex.axis=1.2,
      bty="l")

points(nclutch/nfemales~stack_size,subset(data2,stack_size>10),
       pch=16,
       col="red")

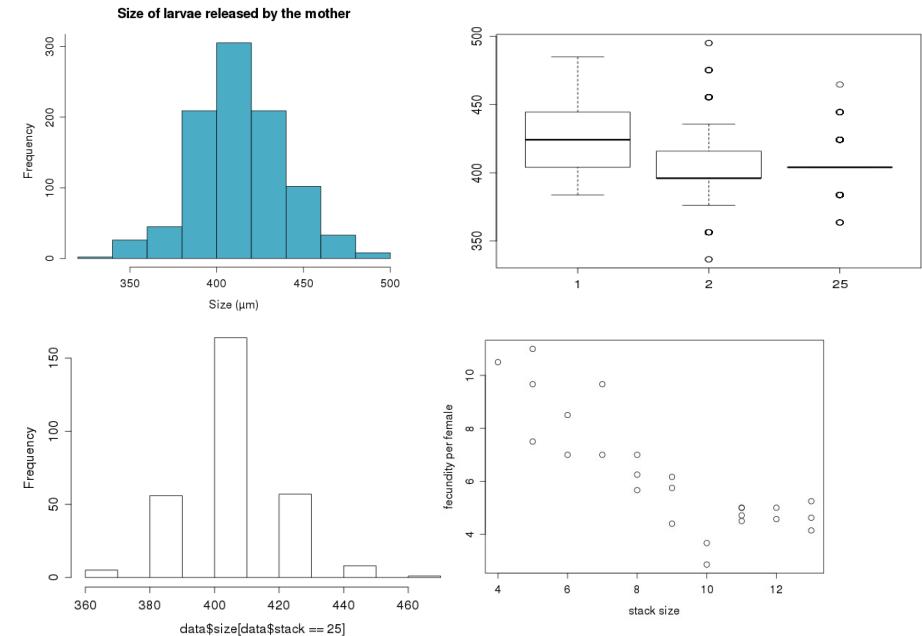
legend(9,10,c("stacks smaller than 10 ind.", "stacks with >10 ind."),
       pch=16,col=c(grey(0.8),"red"),
       bty="n")
```

- Juxtaposition de plusieurs graphiques : version simple

```
# c(nr, nc) : number of row x number of column
par(mfrow(c(2,2)))

hist(data$size,yaxp=c(0,1000,10),col=col1,main="Size of larvae released [...]")
boxplot(size~stack,data)
hist(data$size[data$stack==25])
plot(nclutch/nfemales~stack_size,data=data2,xlab='stack size',ylab='fec [...])
```

- `mfcol()` procède à un remplissage par colonne

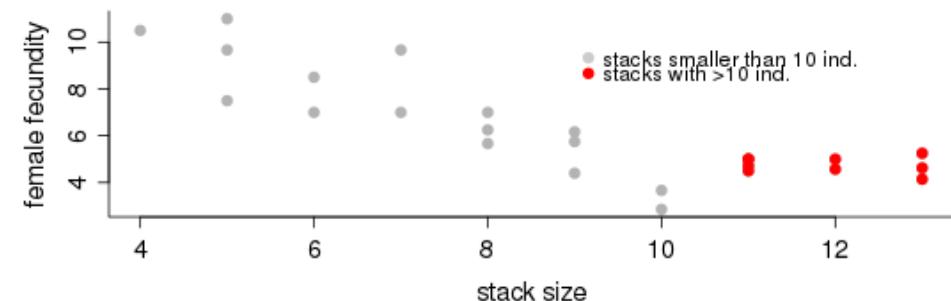
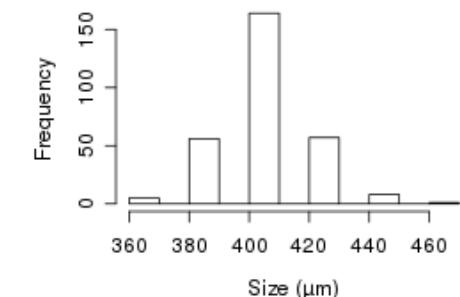
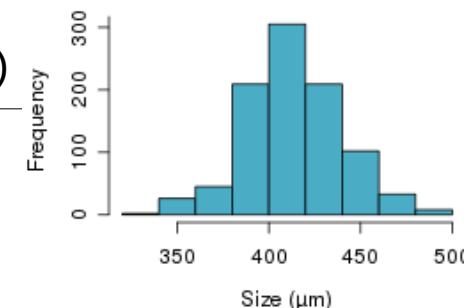


- Juxtaposition de plusieurs graphiques : version étendue

```
# Créer une matrice pour définir les régions du graphique
mat <- matrix(data=c(1,2,3,3),nrow=2,ncol=2,byrow=TRUE)

# Fonction layout
layout(mat)
hist(data$size,[...])
hist(data$size[data$stack==25],[...])
plot(nclutch/nfemales~stack_size,[...])
```

	[,1]	[,2]
[1,]	1	2
[2,]	3	3



# Exportation

- Les sauvegardes R

- RHistory : fichier texte contenant les commandes lancées
- RData : fichier binaire contenant les objets générés
  - Des sauvegardes sont parfois générées automatiquement à la fin de la session : .RHistory et .RData (Cf cours unix : ls -a)



**Attention :** le .RData est chargé automatiquement si vous relancez R dans un répertoire qui en contient un.

- Manuellement :

```
> savehistory("sauvegarde.RHistory")                      # sauver
> source("sauvegarde.RHistory")                            # charger

> save.image("sauvegarde.RData")                           # sauver toute les objets
> save(objet1, objet2, file="objets.RData")               # sauver 2 de mes objets
> load("sauvegarde.RData"))                              # charger
```

- Rappel de l'importation d'un fichier tabulé

```
> paternity = read.table("paternity.tab", header=TRUE, sep="\t", quote="")
```

- Exportation vers un fichier tabulé

```
> write.table(paternity, "paternity.tab", header=TRUE, sep="\t", quote=FALSE)
```

- L'export en pdf se fait en 3 étapes
  - Ouverture d'un fichier pdf
  - Ecriture du (des) graphique(s)
  - Fermeture/Finalisation du fichier pdf

```
pdf(file="graph.pdf")  
  
plot(nclutch/nfemales~stack_size,data2,xlab="stack size",ylab="female [...]")  
points(nclutch/nfemales~stack_size,subset(data2,stack_size>10),pch=16,[...])  
legend(9,10,c("stacks smaller than 10 ind.","stacks with >10 ind."),pc[...])  
  
dev.off()
```

- l'option onefile de pdf() créera une page par plot

- L'export en png se fait en 3 étapes
  - Ouverture d'un fichier png
  - Ecriture du graphique
  - Fermeture/Finalisation du fichier png

```
png(file="graph.png", width = 960, height = 960)

plot(nclutch/nfemales~stack_size,data2,xlab="stack size",ylab="female [...])
points(nclutch/nfemales~stack_size,subset(data2,stack_size>10),pch=16, [...])
legend(9,10,c("stacks smaller than 10 ind.","stacks with >10 ind."),pc [...])

dev.off()
```

- l'option `bg="transparent"` de `png()` peut-être utile

# Un cas d'école

- Cas classique :
  - Un fichier d'annotation mal formaté (...)

```

Gene ID>Contig>Strand>Start>End>GeneType-->description>GO-labels-->protein domains>KOGidLF
Esi0000_0001-->sctg_0-->+-->302>821-->mRNA-->expressed·unknown·protein-->NA-->NA-->NALE
Esi0000_0004-->sctg_0-->+-->6364-->11109-->mRNA-->hypothetical·protein-->NA-->NA-->NALE
Esi0000_0005-->sctg_0-->--->13479-->16792-->mRNA-->conserved·unknown·protein-->NA-->IPR002563:·Flavin·reductase-like,·FMN-binding;·IPR012349:·FMN-bi
Esi0000_0006-->sctg_0-->+-->17040-->21812-->mRNA-->conserved·unknown·protein-->NA-->NA-->NALE
Esi0000_0008-->sctg_0-->--->26488-->30077-->mRNA-->expressed·unknown·protein-->NA-->NA-->NALE
Esi0000_0011-->sctg_0-->--->30876-->40025-->mRNA-->Sphingosine·kinase-->GO:0004143;GO:0007205-->IPR001206:·Diacylglycerol·kinase,·catalytic·region;
Esi0000_0012-->sctg_0-->+-->41042-->48256-->mRNA-->expressed·unknown·protein-->NA-->NA-->NALE
Esi0000_0013-->sctg_0-->+-->50756-->60867-->mRNA-->expressed·unknown·protein-->NA-->NA-->NALE
Esi0000_0014-->sctg_0-->+-->62273-->68202-->mRNA-->conserved·unknown·protein-->NA-->NA-->NALE
Esi0000_0015-->sctg_0-->--->71243-->76115-->mRNA-->bile·Acid:Na+·symporter·family-->NA-->IPR001763:·Rhodanese-like-->NALE
Esi0000_0016-->sctg_0-->--->78257-->78731-->mRNA-->expressed·unknown·protein-->NA-->NA-->NALE
Esi0000_0017-->sctg_0-->+-->79806-->81103-->mRNA-->calmodulin·2-->GO:0005509-->PTHR10891:·CALMODULIN;·IPR011992:·EF-Hand·type;·SSF47473:·EF-hand-->NALE
Esi0000_0018-->sctg_0-->--->81873-->83822-->mRNA-->hypothetical·protein-->NA-->NA-->NALE
Esi0000_0020-->sctg_0-->--->86250-->91784-->mRNA-->conserved·unknown·protein-->GO:0015031-->PTHR22761:·SNF7-->RELATED;·IPR005024:·Snf7-->NALE
Esi0000_0021-->sctg_0-->+-->91943-->100070-->mRNA-->conserved·unknown·protein-->GO:0016491;GO:0055114-->IPR001395:·Aldo/keto·reductase;·IPR020471:·

```

- Une sélection de gènes faite sur la base de transcriptomique

```

Condition-->Gene·IDLF
WT-GA·DW-->Esi0002_0097LF
WT-GA·DW-->Esi0005_0036LF
WT-GA·DW-->Esi0009_0041LF
[...]LF
WT-GA·DW-->Esi0414_0009LF
WT-GA·DW-->Esi0448_0016LF
WT-GA·DW-->no·gene·foundLF
WT-GA·UP-->Esi0000_0099LF
WT-GA·UP-->Esi0002_0166LF
[...]LF
WT-GA·UP-->Esi1543_0001LF
WT-GA·UP-->Esi1667_0001LF

```

- Cas classique :
  - Un fichier d'annotation très mal formaté (...)

otein → GO:0004340;GO:0005524;GO:0006096 →  
5404: Potassium channel, voltage dependen  
→ n/a;n/a;n/a → NA → NA  
→ GO:0004252;GO:0006508;n/a → IPR000595:

→ mRNA → Alanyl-tRNA  
→ mRNA → Soluble  
→ mRNA → conserved

Esi0115\_0039 → sctg\_115 → - → 189614 → 202049 → mRNA → putative phosphatidylinositol 3-kinase →  
→ GO:0016303;GO:0016773;GO:0046854;GO:0048015 → IPR001263: Phosphoinositide 3-kinase accessory region F

- La problématique
  - Mettre en évidence les catégories fonctionnelles (GO) sur/sous exprimées suivant les conditions testées

- La démarche
  - 1. importer le fichier d'annotation
  - 2. "reformater" pour rendre plus pratique l'exploitation des GO terms
  - 3. importer le fichier de transcriptomique
  - 4. fusionner les informations
  - 5. faire les effectifs de termes GO pour chaque condition

## 0. préambule

```

# -----
# 
# This script annotates a selection of genes and compute effective of GO Term
#
#
# --- infileAnnotation :
#
# Gene ID Contig    Strand    Start      End   GeneType  description   GO-labels protein domains      KOGid
# Esi0000_0005 sctg_0    -    13479    16792 mRNA conserved unknown protein    NA   IPR002563: Flav
# Esi0000_0011 sctg_0    -    30876    40025 mRNA Sphingosine kinase  GO:0004143;GO:0007205   IPR00
#
#
# --- infileTranscriptomic :
#
# Condition    Gene ID
# WT-GA DW    Esi0002_0097
# WT-GA DW    Esi0005_0036
# WT-IM UP    Esi0101_0015
# WT-IM UP    Esi0102_0072
#
# -----


options(stringsAsFactors = FALSE)
setwd("/projet/fr2424/informatique/lecorguille/12-09-R-Initiation/input")

# -- parametres annotation

colGO = "GO.labels"
infileAnnotation = "Ectsi_gene_info_LATEST.txt"

# parametres transcriptomic
infileTranscriptomic = "ORO_IMM SAM data gene list d5.113.csv"

```

# 1. importer le fichier d'annotation

```
# -- annotation file -  
  
# import  
  
annotation = read.table(infileAnnotation, sep="\t", quote="", header=TRUE)  
  
#head(annotation[!is.na(annotation[,colGO]),])
```

# 2. "reformater" pour rendre plus pratique l'exploitation des GO

```
# formatage

annotation2 = as.data.frame(matrix(ncol=ncol(annotation), nrow=0))

colGONum = which(colGO == colnames(annotation))
for (row_i in 1:nrow(annotation)) {
  myrow = as.character(annotation[row_i,])

  if (is.na(myrow[colGONum])) {
    annotation2 = rbind(annotation2, myrow)
  } else {
    for (go_i in unlist(strsplit(myrow[colGONum], ";")))) {
      myrow2 = myrow
      myrow2[colGONum] = go_i
      annotation2 = rbind(annotation2, myrow2)
    }
  }
}

# compteur
if ((row_i%%100) == 0) {
  cat (row_i,"/",nrow(annotation),"\n")
}
}

colnames(annotation2) = colnames(annotation)

#head(annotation2[!is.na(annotation2[,colGO]),])
```

### 3. importer le fichier de transcriptomique

```
# -- transcriptomic file : up/down genes -  
  
# import  
  
transcriptomic = read.table(infileTranscriptomic, sep="\t", quote="", header=TRUE)
```

# 4. fusionner les informations

```
# -- merge info --  
  
transciptomicAnnotated = merge(transciptomic, annotation2, by.x = 2, by.y = 1)
```

# 5. faire les effectifs de termes GO pour chaque condition

```
# -- counting -  
  
#allGOs = levels(as.factor(transciptomicAnnotated[,colGO]))  
allGOs = unique(transciptomicAnnotated[,colGO])  
  
allConditions = unique(transciptomicAnnotated[, "Condition"])  
  
for (condition_i in allConditions) {  
  cat(condition_i, "\n")  
  transciptomicAnnotatedCondition = factor(transciptomicAnnotated[transciptomicAnnotated["Condition"]  
    ==condition_i,colGO], levels=allGOs)  
  print(table(transciptomicAnnotatedCondition))  
}
```

Est-ce qu'il y a moyen de faire avec le ~ ?

The Oz