www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

Bulletin de la Dialyse à Domicile

Initiation à la manipulation de données avec le package dplyr

Claire Della Vedova

1087 chemin de Sainte Roustagne, 04100 MANOSQUE, France

Résumé

NDLR : Le RDPLF a pour but principal d'être une aide pour permettre aux équipes de dialyse à domicile d'évaluer leurs pratiques cliniques et également conduire des études à partir d'exports anonymisés des données qu'elles saisissent. A cette fin, depuis juin 2019, un article de formation à l'utilisation du logiciel Libre R est publié trimestriellement à chaque parution du Bulletin de la Dialyse à Domicile. Le but est de permettre à toutes les équipes de réaliser des statistiques de bases et visualiser rapidement leur données.

Le premier article de cette série d'initiation était consacré au téléchargment et à l'installation du logiciel R sur les ordinateurs Macintosh et PC : https://doi.org/10.25796/bdd.v2i2.20513 .

Le second article était consacré à la visualisation graphiques des données statistiques avec le package Esquisse, simple d'utilisation et nécessitant peu d'apprentissage : https://doi.org/10.25796/bdd.v2i3.21313

Le troisième article était consacré à la visualisation graphiques avec le Package ggplot2 : https://doi.org/10.25796/bdd.v2i4.52303

Le quatrième article expliquait comment générer un rapport d'analyse automatiquement, et de façon dynamique, en utilisant "Rmarkdown".

Ce cinquième article est consacré à la manipulation des données avec le package dplyr : https://doi.org/10.25796/bdd.v3i1.54523

Comme dans les numéros précédent un fichier exemple, tiré de la base de données du RDPLF sera utlisé.

Claire Della Vedova est Ingénieure en biostatistique / data analyste, Elle utilise quotidiennement le logiciel R pour analyser des données. Elle a travaillé pendant plus de 15 ans dans les domaines de l'environnement et de la santé, et a formé de nombreux étudiants et chercheurs à l'utilisation de R. Elle anime depuis novembre 2017 le blog Statistique et Logiciel R dont le but est d'aider les débutants à mieux appréhender les méthodes statistiques classiques et à utiliser le logiciel R plus efficacement, notamment au travers de tutoriels : https://statistique-et-logiciel-r.com/.

La formation totale se fait sur 15 mois, au rythme d'un article par trimestre à chaque parution du BDD. Cela laissera largement le temps d'assimiler et tester les connaissances acquises entre chaque article. Pour ceux qui souhaiteront aller plus vite, ils pourront aller sur le blog (https://statistique-et-logiciel-r.com/).

Dates des prochaines parutions :

- article 6 (Septembre 2020) : la réalisation d'analyses descriptives (paramètres statistiques et graphs) sous forme de dashboard avec le package flexboard

Mots clés : Statistiques, épidemiologie, RDPLF, Logiciel libre R, cours de statistiques

journal officiel du Registre de Dialyse Péritonéale de Langue Française **RDPLF** www.rdplf.org

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

1. Introduction

L'analyse de données nécessite bien souvent de savoir manipuler des tableaux de données, par exemple pour sélectionner des colonnes, filtrer des lignes, ou encore calculer des paramètres sur un sous-groupe d'observations.
Sous R, toutes ces manipulations peuvent facilement être réalisées, en employant le package dplyr (qui appartient, comme le package ggplot2, au super package tidyverse).
Les principales fonctions à connaître, pour débuter dans la manipulation de données sont :

- select() : pour sélectionner des colonnes,
- filter() : pour sélectionner des lignes,
- mutate() : pour créer des variables,
- summarise() : pour résumer des données, en calculant des paramètres descriptifs,
- group_by() : pour regrouper les données (avant de calculer un paramètre descriptif par exemple).

Ces cinq fonctions peuvent s'utiliser les unes après les autres, en utilisant le symbole %>% (pipe en anglais), que l'on pourrait traduire par "et puis".

Nous allons les explorer une à une à travers quelques exemples.

Le package dispose d'une cheat sheet, elle peut être téléchargée à partir de R Studio et de l'onglet Help –> Cheatsheets –> Data Transformation with dplyr.

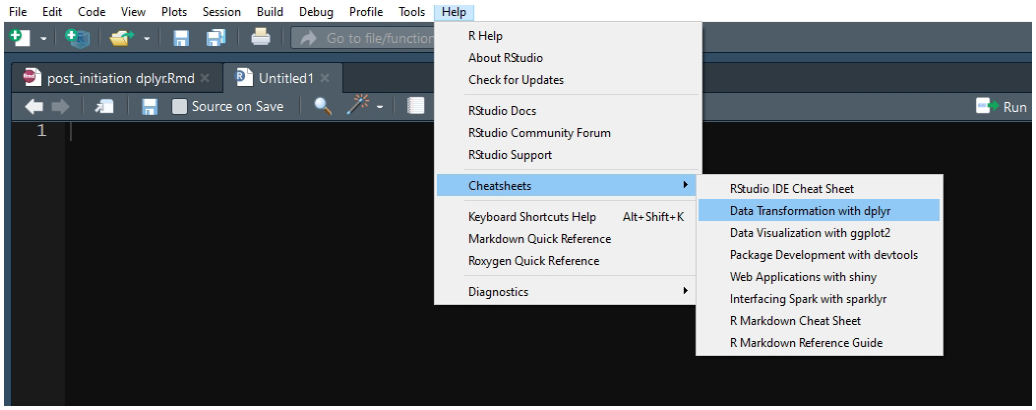

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

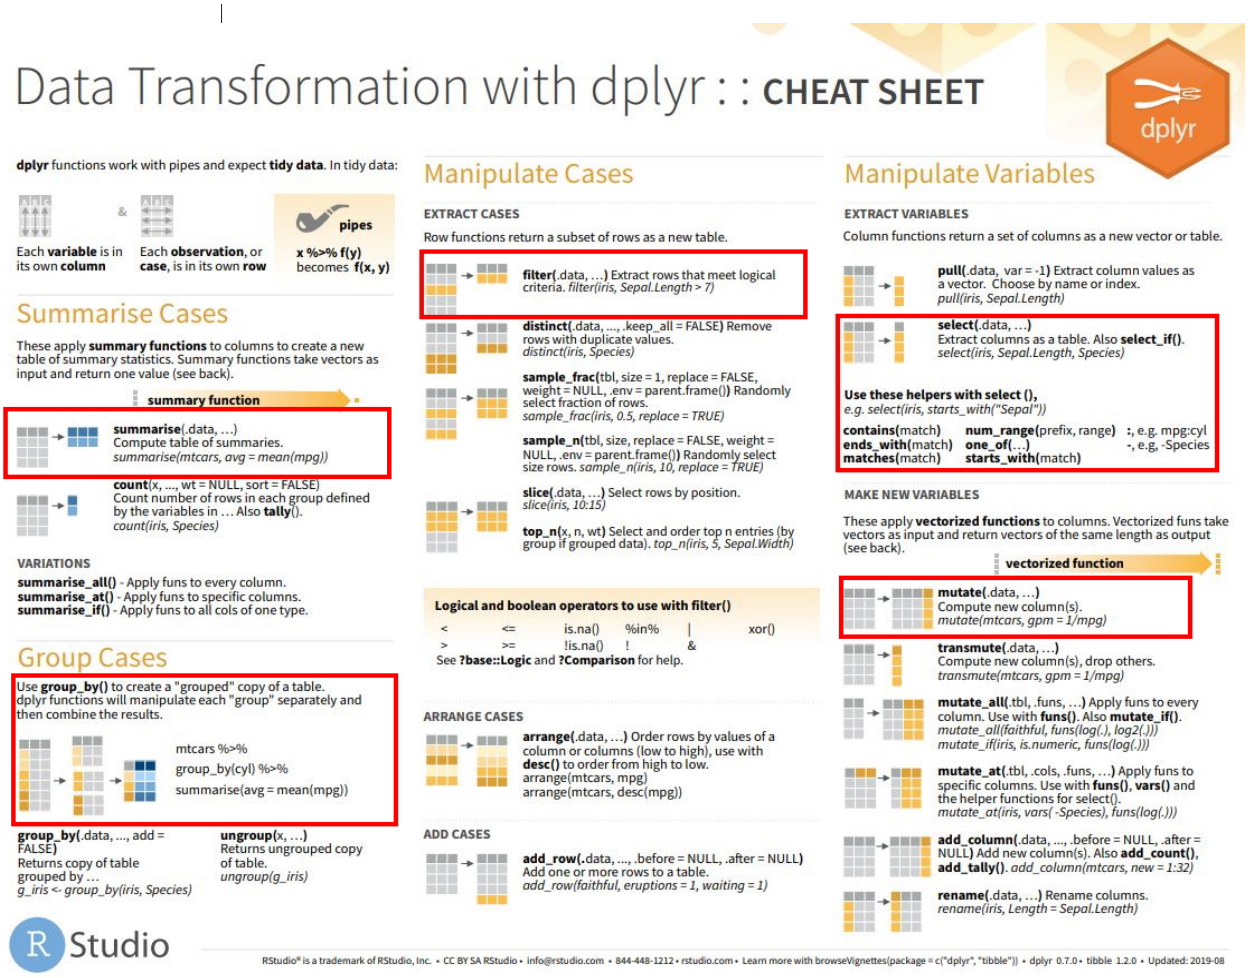

2. Avant de commencer

2.1 Organiser son travail

Avant de commencer à explorer les fonctions du package dplyr je vous recommande de créer un dossier de travail dédié à votre analyse de données, et de l'associer à un projet R.

Vous trouverez plus d'information sur cette étape dans le premier article de cette série dédiée à l'utilisation du logiciel R https://www.bdd.rdplf.org/index.php/bdd/article/view/20513.

Les données utilisées dans les exemples ci-dessous, sont les mêmes que celles des articles précédents, elles sont téléchargeables au format csv, à cette adresse : https://www.rdplf.org/exempleR/FichierExempleStat.csv

Une fois téléchargé, placez le fichier csv dans le dossier "data" de votre projet R, puis utilisez la commande suivante pour les importer dans R :

```
mydata <- read.csv2(«data/FichierExempleStat.csv»)
```

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

2.2 Charger le package dplyr

Pour charger le package dplyr, vous pouvez employer l'une des deux commandes suivantes :

```
library(dplyr)
library(tidyverse)
```

2.2 Gérer les éventuels conflits de packages

Un conflit de package peut survenir lorsque deux packages contiennent des fonctions différentes mais portant le même nom. C'est le cas, par exemple, de la fonction select() du package dplyr, et de la fonction select() du package MASS. En cas de conflits de packages, R ne sait pas quelle fonction choisir. Au mieux, il vous renverra une erreur dont le message est rarement intelligible, au pire, il ne fera rien : il n'exécutera pas la commande et vous ne le signalera pas !

Pour éviter cette situation, je vous recommande de spécifier, en amont de vos scripts, que vous souhaitez utiliser les fonctions select() et filter() du package dplyr, en utilisant le package conflicted et sa fonction conflict_prefer(), comme ceci :

```
library(conflicted)
conflict_prefer(«select», «dplyr»)
conflict_prefer(«filter», «dplyr»)
```

Remarque : à ma connaissance les fonctions mutate(), summarise() et group_by ne sont pas (actuellement) concernées par un éventuel conflit de package.

3. Selectionner des variables

Pour créer un sous-jeu de données en ne sélectionnant que certaines variables, nous employons la fonction select().

3.1 Par le nom

Si nous souhaitons faire un nouveau fichier de données, avec uniquement les variables PAYS, sexe, Charlson, Taille et Poids, il suffit de les indiquer en argument de la fonction select() :

```
mydata2 <- mydata %>%
  select(PAYS, sexe, Charlson, Taille, Poids)
# vérification des variables présentes dans le jeu créé
head(mydata2)

##                PAYS  sexe Charlson Taille Poids
## 1            FRANCE     F        3    132  30.0
## 2           TUNISIE     F        3    131  32.5
## 3 LUXEMBOURG        M        5    140  33.0
## 4            FRANCE     F        6    142  35.0
## 5            FRANCE     F        6    150  35.0
## 6            FRANCE     F        4    145  37.0
```

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

3.2 Désélectionner le nom

Il est également possible de désélectionner des variables, en employant le symbole "-" devant celles-ci :

```
mydata3 <- mydata %>%
  select(-code.post, -Age.1ere.DP,-Charlson_modif, -Type.de.DP)

# verification
head(mydata3)

##                PAYS  sexe  Charlson  Taille  Poids
## 1            FRANCE     F         3     132   30.0
## 2            TUNISIE    F         3     131   32.5
## 3 LUXEMBOURG        M         5     140   33.0
## 4            FRANCE     F         6     142   35.0
## 5            FRANCE     F         6     150   35.0
## 6            FRANCE     F         4     145   37.0
```

3.3 Sélection par nom partiel

Il est encore possible de sélectionner des variables en utilisant un motif de lettres contenu dans le nom des variables. Par exemple, si nous souhaitons sélectionner toutes les variables contenant le motif "Charlson" :

```
mydata4 <- mydata %>%
  select(contains(«Charlson»))

# verification
head(mydata4)

##    Charlson Charlson_modif
## 1         3              3
## 2         3              2
## 3         5              5
## 4         6              5
## 5         6              5
## 6         4              3
```

Nous pouvons aussi employer les fonctions starts_with() et ends_with(). Par exemple, pour sélectionner les variables se terminant par le motif de lettres "DP" :

```
mydata5 <- mydata %>%
  select(ends_with(«DP»))
# vérification
head(mydata5)

##    Age.1ere.DP        Type.de.DP
## 1        20.13              DPCA
## 2        50.74              DPCA
## 3        18.86  DPA quotidienne
## 4        50.86  DPA quotidienne
## 5        54.07              DPCA
## 6        53.89              DPCA
```

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

3.4 Sélection par classe de variable

En complément de la fonction select(), le package dplyr dispose d'une fonction select_if() qui permet, par exemple de sélectionner des variables en fonction de leur classe (numérique ou factoriel).
Ainsi, si nous souhaitons, sélectionner toutes les variables numérique d'un data frame, nous pouvons employer la commande suivante :

```
mydata_num <- mydata %>%
  select_if(is.numeric)

head(mydata_num)
```

```
##   Age.1ere.DP Charlson Charlson_modif Taille Poids
## 1       20.13        3             3    132  30.0
## 2       50.74        3             2    131  32.5
## 3       18.86        5             5    140  33.0
## 4       50.86        6             5    142  35.0
## 5       54.07        6             5    150  35.0
## 6       53.89        4             3    145  37.0
```

De même pour les variables catégorielles :

```
mydata_fact <- mydata %>%
  select_if(is.factor)

head(mydata_fact)
```

```
##   code.post       PAYS sexe       Type.de.DP
## 1     56100     FRANCE    F             DPCA
## 2      1006    TUNISIE    F             DPCA
## 3      2540 LUXEMBOURG    M DPA quotidienne
## 4      3200     FRANCE    F DPA quotidienne
## 5     31603     FRANCE    F             DPCA
## 6     74374     FRANCE    F             DPCA
```

4. Filtrer des lignes

La fonction filter() permet de filtrer des lignes, notamment en fonction:
- d'une variable numérique
- d'une variable catégorielle (facteur)

4.1 En fonction d'une variable numérique

Par exemple, si nous souhaitons conserver uniquement les patients dont l'âge de la première DP est supérieur à 65 ans :

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

```
sup65 <-mydata %>%
  filter(Age.1ere.DP>65)

head(sup65)
##   code.post      PAYS sexe Age.1ere.DP Charlson Charlson_modif       Type.de.DP
## 1     25000 FRANCE    F        86.50        7             3             DPCA
## 2     83100 FRANCE    F        83.75        7             3             DPCA
## 3     72037 FRANCE    F        71.58        7             4 DPA quotidienne
## 4     97448 FRANCE    F        76.88        5             2 DPA quotidienne
## 5      3200 FRANCE    F        69.25        4             2             DPCA
## 6     54504 FRANCE    F        86.53        7             3             DPCA
##   Taille Poids
## 1    147    38
## 2    139    39
## 3    157    39
## 4    145    40
## 5    152    40
## 6    155    40
```

Nous pouvons également employer un intervalle de valeurs, comme ceci :

```
entre55_65 <- mydata %>%
  filter(between(Age.1ere.DP, 55, 65))

head(entre55_65 )
##   code.post      PAYS sexe Age.1ere.DP Charlson Charlson_modif       Type.de.DP
## 1     59037    FRANCE    F        56.06        3             2             DPCA
## 2      1200 BELGIQUE    F        63.29        8             6 DPA quotidienne
## 3      4500 BELGIQUE    F        57.30        4             3 DPA quotidienne
## 4     44402    FRANCE    F        58.72        6             5 DPA quotidienne
## 5     31603    FRANCE    F        61.35        4             2             DPCA
## 6     29000    FRANCE    F        63.62        6             4             DPCA
##   Taille Poids
## 1    135  42.0
## 2    157  43.0
## 3    167  43.0
## 4    162  44.0
## 5    145  44.5
## 6    157  45.0
```

4.2 En fonction d'une variable catégorielle

Si nous souhaitons réaliser un sous-jeu de données, ne contenant que les observations relatives à la France :

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

```
df_Fr <- mydata %>%
  filter(PAYS==»FRANCE»)

head(df_Fr)

##   code.post      PAYS sexe Age.1ere.DP Charlson Charlson_modif         Type.de.DP
## 1     56100 FRANCE    F        20.13        3              3               DPCA
## 2      3200  FRANCE    F        50.86        6              5  DPA quotidienne
## 3     31603 FRANCE    F        54.07        6              5               DPCA
## 4     74374 FRANCE    F        53.89        4              3               DPCA
## 5     25000 FRANCE    F        86.50        7              3               DPCA
## 6     83100 FRANCE    F        83.75        7              3               DPCA
##   Taille  Poids
## 1    132     30
## 2    142     35
## 3    150     35
## 4    145     37
## 5    147     38
## 6    139     39
```

Pour sélectionner plusieurs pays, il est nécessaire de créer le vecteur de pays, et d'employer le symbole %in%, comme ceci :

```
df_Su_Be_Lu <- mydata %>%
  filter(PAYS %in% c( «SUISSE», «BELGIQUE», «LUXEMBOURG»))

head(df_Su_Be_Lu)

##   code.post          PAYS sexe Age.1ere.DP Charlson Charlson_modif       Type.de.DP
## 1      2540 LUXEMBOURG    M        18.86        5              5  DPA quotidienne
## 2      1211         SUISSE    F        28.61        2              2             DPCA
## 3      1200      BELGIQUE    F        17.38        3              3  DPA quotidienne
## 4      1011         SUISSE    F        47.00        3              3  DPA quotidienne
## 5      1200      BELGIQUE    F        63.29        8              6  DPA quotidienne
## 6      1211         SUISSE    F        77.76        6              3  DPA quotidienne
##   Taille  Poids
## 1    140     33
## 2    154     41
## 3    147     42
## 4    150     43
## 5    157     43
## 6    157     43
```

4.3 En fonction d'un double critère.

Par exemple si nous souhaitons filtrer les femmes de plus de 170 cm

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

```
Fsup170 <- mydata %>%
  filter(sexe==»F») %>%
  filter(Taille>170)

head(Fsup170)

##   code.post      PAYS sexe Age.1ere.DP Charlson Charlson_modif        Type.de.DP
## 1     59385  FRANCE    F       64.90        4             2 DPA quotidienne
## 2     75020  FRANCE    F       20.73        2             2 DPA quotidienne
## 3     83100  FRANCE    F       58.74       15            14 DPA quotidienne
## 4     35400  FRANCE    F       77.03        7             4              DPCA
## 5     62408  FRANCE    F       46.60        3             3              DPCA
## 6      5000  TUNISIE   F       21.63        2             2              DPCA
##   Taille Poids
## 1    175     45
## 2    172     48
## 3    172     52
## 4    172     54
## 5    171     56
## 6    171     58
```

A noter que nous pouvons également employer la syntaxe suivante :

```
Fsup170bis <- mydata %>%
  filter(sexe==»F» & Taille>170 )
```

4.4 En fonction d'une position

Pour filtrer des lignes en fonction de leur position (index), nous pouvons employer la fonction slice().

Par exemple, pour ne conserver que les lignes 5 à 10 du jeu de données :

```
mydata_5to10 <- mydata %>%
  slice(5:10)

mydata_5to10

##   code.post      PAYS sexe Age.1ere.DP Charlson Charlson_modif        Type.de.DP
## 1     31603  FRANCE    F       54.07        6             5              DPCA
## 2     74374  FRANCE    F       53.89        4             3              DPCA
## 3     20420   MAROC    F       22.25        2             2              DPCA
## 4     25000  FRANCE    F       86.50        7             3              DPCA
## 5     10000   MAROC    F       18.22        2             2 DPA quotidienne
## 6     83100  FRANCE    F       83.75        7             3              DPCA
##   Taille Poids
## 1    150     35
## 2    145     37
## 3    148     37
## 4    147     38
## 5    136     39
## 6    139     39
```

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

Pour filtrer des lignes, non contiguës, en fonction de leur position, il est nécessaire d'employer la concaténation, comme dans l'exemple ci-dessous :

```
mydata_multiple <- mydata %>%
  slice(c(2:4),59,c(111:113))
mydata_multiple

##   code.post          PAYS sexe Age.1ere.DP Charlson Charlson_modif       Type.de.DP
## 1      1006       TUNISIE    F       50.74        3              2             DPCA
## 2      2540    LUXEMBOURG    M       18.86        5              5 DPA quotidienne
## 3      3200        FRANCE    F       50.86        6              5 DPA quotidienne
## 4     10000         MAROC    M       33.62        2              2             DPCA
## 5      1020      BELGIQUE    F       28.62        8              8 DPA quotidienne
## 6     75014        FRANCE    M       17.85        2              2             DPCA
## 7     46005        FRANCE    F       46.52        2              2 DPA quotidienne
##   Taille Poids
## 1    131  32.5
## 2    140  33.0
## 3    142  35.0
## 4    159  44.0
## 5    165  46.0
## 6    165  46.0
## 7    168  46.0
```

4.5 Liste des principaux opérateurs

Les principaux opérateurs qui peuvent être employés avec la fonction filter() sont résumés ci-dessous :

Opérateur	Signification
<	strictement inférieur
<=	inférieur ou égal
>	strictement supérieur
>=	supérieur ou égal
==	exactement égal
!=	différent
x|y	x et/ou y
xor(x,y)	x ou y (intersection exclue)
x & y	x et y
is.na(x)	test si x est NA
%in%	compris dans (un vecteur de choix)

5. Créer une nouvelle variable

La fonction mutate() permet de créer une nouvelle variable dans un data.frame.

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

5.1 Une variable numérique

Par exemple, si nous souhaitons créer une nouvelle variable taille, exprimée cette fois en mètres :

```
mydata <- mydata %>%
  mutate(Taille_m=Taille/100)

head(mydata)
```

```
##   code.post              PAYS sexe Age.1ere.DP Charlson Charlson_modif        Type.de.DP
## 1     56100            FRANCE    F       20.13        3             3              DPCA
## 2      1006           TUNISIE    F       50.74        3             2              DPCA
## 3      2540 LUXEMBOURG    M       18.86        5             5 DPA quotidienne
## 4      3200            FRANCE    F       50.86        6             5 DPA quotidienne
## 5     31603            FRANCE    F       54.07        6             5              DPCA
## 6     74374            FRANCE    F       53.89        4             3              DPCA
##   Taille Poids Taille_m
## 1    132   30.0     1.32
## 2    131   32.5     1.31
## 3    140   33.0     1.40
## 4    142   35.0     1.42
## 5    150   35.0     1.50
## 6    145   37.0     1.45
```

Si nous souhaitons, à présent, créer une variable IMC à partir du poids et de la taille des patients, en divisant le poids par la taille (exprimée en mètre) :

```
mydata <- mydata %>%
  mutate(IMC = Poids/(Taille_m))

head(mydata)
```

```
##   code.post              PAYS sexe Age.1ere.DP Charlson Charlson_modif        Type.de.DP
## 1     56100            FRANCE    F       20.13        3             3              DPCA
## 2      1006           TUNISIE    F       50.74        3             2              DPCA
## 3      2540 LUXEMBOURG    M       18.86        5             5 DPA quotidienne
## 4      3200            FRANCE    F       50.86        6             5 DPA quotidienne
## 5     31603            FRANCE    F       54.07        6             5              DPCA
## 6     74374            FRANCE    F       53.89        4             3              DPCA
##   Taille Poids Taille_m      IMC
## 1    132   30.0     1.32 22.72727
## 2    131   32.5     1.31 24.80916
## 3    140   33.0     1.40 23.57143
## 4    142   35.0     1.42 24.64789
## 5    150   35.0     1.50 23.33333
## 6    145   37.0     1.45 25.51724
```

5.2 Une variable catégorielle

En couplant la fonction ifelse(), à la fonction mutate(), il est par exemple possible de catégoriser une variable numérique. Cette fonction ifelse() prend trois arguments :

- la condition
- la valeur que prend la variable si la condition est satisfaite
- la valeur que prend la variable sinon.

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

Par exemple si nous souhaitons créer une variable “Stature” qui prend pour valeur “petite” si la taille est inférieure ou égale 166 cm, et “grande” sinon, nous pouvons employer les commandes suivantes :

```
mydata <- mydata %>%
  mutate(Stature = ifelse(Taille<=166, «Petite», «Grande»))

# visualisation du résultat
sample_n(mydata,10)
```

	code.post	PAYS	sexe	Age.1ere.DP	Charlson	Charlson_modif	Type.de.DP
1	38701	FRANCE	M	71.59	9	6	DPA quotidienne
2	11100	FRANCE	F	50.75	4	3	DPCA
3	13698	FRANCE	M	46.96	2	2	DPCA
4	84902	FRANCE	M	63.92	5	3	DPA quotidienne
5	62408	FRANCE	M	81.37	2	-2	DPCA
6	54504	FRANCE	M	78.86	6	3	DPCA
7	14033	FRANCE	F	68.18	5	3	DPCA
8	4000	TUNISIE	F	23.99	2	2	DPA quotidienne
9	94275	FRANCE	F	63.95	4	2	DPCA
10	4000	BELGIQUE	M	51.81	3	2	DPA quotidienne

	Taille	Poids	Taille_m	IMC	Stature
1	175	86	1.75	49.14286	Grande
2	160	82	1.60	51.25000	Petite
3	170	87	1.70	51.17647	Grande
4	176	82	1.76	46.59091	Grande
5	172	87	1.72	50.58140	Grande
6	180	53	1.80	29.44444	Grande
7	148	53	1.48	35.81081	Petite
8	155	52	1.55	33.54839	Petite
9	165	106	1.65	64.24242	Petite
10	175	88	1.75	50.28571	Grande

5.3 Transformer une variable

La fonction mutate peut également permettre de modifier une variable existante, plutôt que d’en créer une autre. Pour cela, ce sont surtout les fonctions mutate_if() et mutate_at() qui sont employées.
Par exemple, pour centrer et réduire les variables numériques de notre jeu de données, nous pouvons coupler les fonctions mutate_if() et scale() qui permet le centrage réduction, comme ceci :

```
mydata_num_cr <- mydata %>%
  mutate_if(is.numeric, scale)
head(mydata_num_cr)
```

	code.post	PAYS	sexe	Age.1ere.DP	Charlson	Charlson_modif
1	56100	FRANCE	F	-2.7237972	-1.12386300	-0.3901693
2	1006	TUNISIE	F	-0.8685743	-1.12386300	-0.9416180
3	2540	LUXEMBOURG	M	-2.8007698	-0.33322084	0.7127281
4	3200	FRANCE	F	-0.8613013	0.06210025	0.7127281
5	31603	FRANCE	F	-0.6667484	0.06210025	0.7127281
6	74374	FRANCE	F	-0.6776579	-0.72854192	-0.3901693

	Type.de.DP	Taille	Poids	Taille_m	IMC	Stature
1	DPCA	-3.490473	-2.724799	-3.490473	-2.479468	Petite
2	DPCA	-3.592773	-2.565011	-3.592773	-2.232003	Petite
3	DPA quotidienne	-2.672075	-2.533053	-2.672075	-2.379127	Petite
4	DPA quotidienne	-2.467476	-2.405222	-2.467476	-2.251172	Petite
5	DPCA	-1.649077	-2.405222	-1.649077	-2.407428	Petite
6	DPCA	-2.160576	-2.277392	-2.160576	-2.147836	Petite

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

La fonction mutate_at() est employer pour préciser les variables numériques que nous souhaitons centrer réduire:

```
mydata_num_cr2 <- mydata %>%
  mutate_at(«Age.1ere.DP», scale)
head(mydata_num_cr2)
```

```
##   code.post          PAYS sexe  Age.1ere.DP Charlson Charlson_modif       Type.de.DP
## 1     56100        FRANCE    F   -2.7237972        3              3             DPCA
## 2      1006       TUNISIE    F   -0.8685743        3              2             DPCA
## 3      2540    LUXEMBOURG    M   -2.8007698        5              5 DPA quotidienne
## 4      3200        FRANCE    F   -0.8613013        6              5 DPA quotidienne
## 5     31603        FRANCE    F   -0.6667484        6              5             DPCA
## 6     74374        FRANCE    F   -0.6776579        4              3             DPCA
##    Taille  Poids  Taille_m       IMC  Stature
## 1     132   30.0      1.32  22.72727   Petite
## 2     131   32.5      1.31  24.80916   Petite
## 3     140   33.0      1.40  23.57143   Petite
## 4     142   35.0      1.42  24.64789   Petite
## 5     150   35.0      1.50  23.33333   Petite
## 6     145   37.0      1.45  25.51724   Petite
```

5.4 Liste des fonctions utilisables

Le package dyplr propose de nombreuses fonctions très utiles qui peuvent être employées dans une fonction mutate() pour transformer ou créer des variables :

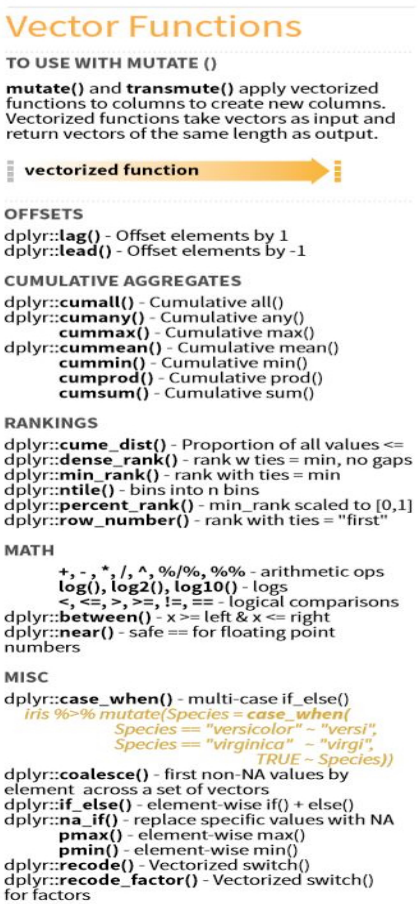

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

6 Calculer un paramètre

6.1 De manière globale

La fonction summarise() permet de calculer un paramètre descriptif, comme une moyenne, la valeur minimum, la valeur maximum etc… Voici un exemple de commande qui peut être employée pour calculer la moyenne, la médiane, le min, le max et l'écart type de la Taille :

```
mydata %>%
  summarise(moy=mean(Taille, na.rm=TRUE),
            med=median(Taille, na.rm=TRUE),
            min=min(Taille, na.rm=TRUE),
            max=max(Taille, na.rm=TRUE),
            ecart_type=sd(Taille, na.rm=TRUE))

##          moy  med  min  max  ecart_type
## 1  166.1201   166  100   196   9.775194
```

6.2 Par sous-groupes

Un des grands intérêts de cette fonction summarise(), réside dans son couplage avec la fonction group_by(). La combinaison de ces fonctions permet alors d'obtenir l'estimation de paramètres pour différents sous-groupes de données.

Ainsi, si nous souhaitons obtenir les paramètres précédents, en fonction des pays, nous pouvons employer en amont la syntaxe group_by(PAYS)%>%, comme ceci :

```
mydata %>%
  group_by(PAYS) %>%
  summarise(Nb=n(),
            moy=mean(Taille, na.rm=TRUE),
            med=median(Taille, na.rm=TRUE),
            min=min(Taille, na.rm=TRUE),
            max=max(Taille, na.rm=TRUE),
            ecart_type=sd(Taille, na.rm=TRUE))

## # A tibble: 6 x 7
##   PAYS          Nb   moy   med   min   max ecart_type
##   <fct>      <int> <dbl> <dbl> <dbl> <dbl>      <dbl>
## 1 BELGIQUE     244  167.   168   120   194       9.24
## 2 FRANCE      2639  166.   166   100   196       9.74
## 3 LUXEMBOURG    10  171.   174   140   195       16.5
## 4 MAROC         99  164.   165   126   186       10.3
## 5 SUISSE        33  167.   168   150   185       10.3
## 6 TUNISIE      107  166.   168   131   190       10.1
```

Nous pouvons utiliser plusieurs variables dans la fonction group_by(), par exemple le pays et le sexe, comme ceci :

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

```
mydata %>%
  group_by(PAYS, sexe) %>%
  summarise(Nb=n(),
            moy=mean(Taille, na.rm=TRUE),
            med=median(Taille, na.rm=TRUE),
            min=min(Taille, na.rm=TRUE),
            max=max(Taille, na.rm=TRUE),
            ecart_type=sd(Taille, na.rm=TRUE))
```

```
## # A tibble: 12 x 8
## # Groups:   PAYS [6]
##    PAYS          sexe     Nb   moy   med   min   max ecart_type
##    <fct>         <fct>  <int> <dbl> <dbl> <dbl> <dbl>      <dbl>
##  1 BELGIQUE      F         91  161.   162   140   177       6.90
##  2 BELGIQUE      M        153  171.   170   120   194       8.44
##  3 FRANCE        F       1056  159.   159   120   186       7.48
##  4 FRANCE        M       1583  171.   170   100   196       8.12
##  5 LUXEMBOURG    F          2  158.   158.  151   164       9.19
##  6 LUXEMBOURG    M          8  175.   176   140   195      16.4
##  7 MAROC         F         55  159.   160   126   178       9.07
##  8 MAROC         M         44  171.   170   154   186       7.87
##  9 SUISSE        F         13  158.   157   150   172       6.63
## 10 SUISSE        M         20  173.   174.  155   185       7.54
## 11 TUNISIE       F         48  161.   161   131   184       9.10
## 12 TUNISIE       M         59  171.   172   145   190       8.35
```

Et bien entendu, si nous le souhaitons, nous pouvons stocker ces paramètres dans une nouvelle table de données, qui pourra ensuite, par exemple, être utilisée pour créer des visualisations. Pour cela, il nous suffit d'utiliser une assignation (avec une flèche, en amont) :

```
new_table <- mydata %>%
  group_by(PAYS, sexe) %>%
  summarise(Nb=n(),
            moy=mean(Taille, na.rm=TRUE),
            med=median(Taille, na.rm=TRUE),
            min=min(Taille, na.rm=TRUE),
            max=max(Taille, na.rm=TRUE),
            ecart_type=sd(Taille, na.rm=TRUE))


head(new_table)
```

```
## # A tibble: 6 x 8
## # Groups:   PAYS [3]
##   PAYS          sexe     Nb   moy   med   min   max ecart_type
##   <fct>         <fct>  <int> <dbl> <dbl> <dbl> <dbl>      <dbl>
## 1 BELGIQUE      F         91  161.   162   140   177       6.90
## 2 BELGIQUE      M        153  171.   170   120   194       8.44
## 3 FRANCE        F       1056  159.   159   120   186       7.48
## 4 FRANCE        M       1583  171.   170   100   196       8.12
## 5 LUXEMBOURG    F          2  158.   158.  151   164       9.19
## 6 LUXEMBOURG    M          8  175.   176   140   195      16.4
```

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

6.3 Liste des fonctions utilisables dans summarise():

Voici une liste de fonctions qui peuvent être utilisée dans la fonction summarise() pour résumer de l'information :

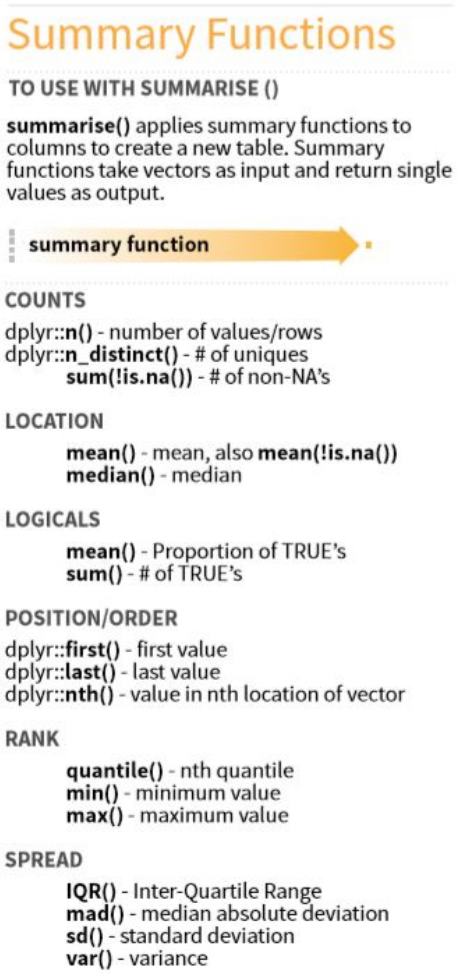

7. Conclusion

J'espère que cet article vous aura convaincu, à la fois sur les capacités du package dplyr à manipuler les données, mais aussi sur sa facilité d'utilisation.

Notez, néanmoins, que les fonctions select(), filter(), mutate(), et summarise() offrent de nombreuses autres possibilités, qu'il est impossible de détailler dans un seul article.

Si vous souhaitez explorer ces possibilités, vous pouvez consulter le blog de suzan Baert, notamment les pages :

- Data Wrangling Part 1: Basic to Advanced Ways to Select Columns https://suzan.rbind.io/2018/01/dplyr-tutorial-1/
- Data Wrangling Part 2: Transforming your columns into the right shape https://suzan.

www.bdd.rdplf.org Volume 3, n°2 , Juin 2020
https://doi.org/ 10.25796/bdd.v3i2.55463
ISSN 2607-9917

rbind.io/2018/02/dplyr-tutorial-2/

- Data Wrangling Part 3: Basic and more advanced ways to filter rows https://suzan.rbind.io/2018/02/dplyr-tutorial-3/
- Data Wrangling Part 4: Summarizing and slicing your data https://suzan.rbind.io/2018/04/dplyr-tutorial-4/