Remaniement de données

avec dplyr et tidyr

Aide-mémoire

RStudio

Syntaxe - conventions utiles

dplyr::**tbl_df(iris)**

Convertit le jeu de données en classe *tbl* .
Les *tbl* sont plus faciles à explorer que les data frames :
R n'affiche que les données adaptées à la taille de l'écran

```
Source: local data frame [150 x 5]

   Sepal.Length Sepal.Width Petal.Length
1           5.1         3.5          1.4
2           4.9         3.0          1.4
3           4.7         3.2          1.3
4           4.6         3.1          1.5
5           5.0         3.6          1.4
..          ...         ...          ...
Variables not shown: Petal.Width (dbl),
  Species (fctr)
```

dplyr::**glimpse(iris)**

Fournit un résumé des jeux de données de class *tbl*

utils::**View(iris)**

Affiche les données dans un tableur (attention au V majuscule)

	Sepal.Length	Sepal.Width	Petal.Length	Petal.Width	Species
1	5.1	3.5	1.4	0.2	setosa
2	4.9	3.0	1.4	0.2	setosa
3	4.7	3.2	1.3	0.2	setosa
4	4.6	3.1	1.5	0.2	setosa
5	5.0	3.6	1.4	0.2	setosa
6	5.4	3.9	1.7	0.4	setosa
7	4.6	3.4	1.4	0.3	setosa
8	5.0	3.4	1.5	0.2	setosa

dplyr::**%>%**

Passe l'objet se trouvant à gauche comme premier argument de la fonction se trouvant à droite.

`x %>% f(y)` *équivaut à* `f(x, y)`
`y %>% f(x, ., z)` *équivaut à* `f(y, x, z)`

Utiliser l'opérateur %>% rend le code plus lisible :

```
iris %>%
  group_by(Species) %>%
  summarise(avg = mean(Sepal.Width)) %>%
  arrange(avg)
```

Jeu de données ordonné - la base du remaniement de données

Dans un jeu de données dit « ordonné » :

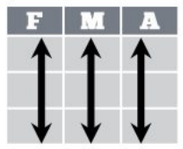

Chaque variable est en colonne et…

&

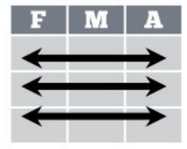

…chaque observation est en ligne

Les jeux de données ordonnés sont complémentaires de la vectorisation dans R.
R préserve les observations quand les variables sont manipulées.
Aucun autre format ne fonctionne aussi intuitivement que celui de R.

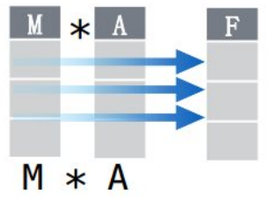

Réorganisation des données - changer la disposition des données

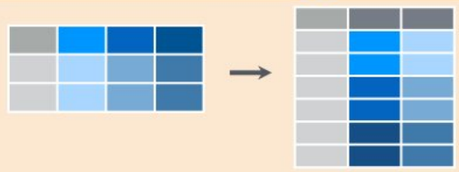

tidyr::**gather(cases, "year", "n", 2:4)**

Fusionne des colonnes en lignes.

tidyr::**separate(storms, date, c("y", "m", "d"))**

Divise une colonne en plusieurs.

tidyr::**spread(pollution, size, amount)**

Distribue les lignes dans des colonnes.

tidyr::**unite(data, col, ..., sep)**

Concatène plusieurs colonnes en une seule.

dplyr::**data_frame(a = 1:3, b = 4:6)**

Combine les vecteurs dans un *data frame* (de façon optimisée).

dplyr::**arrange(mtcars, mpg)**

Trie les observations par les valeurs d'une variable (ordre croissant).

dplyr::**arrange(mtcars, desc(mpg))**

Trie les observations par les valeurs d'une colonne (ordre décroissant).

dplyr::**rename(tb, y = year)**

Renomme les variables du jeu de données.

Extraction d' observations (lignes)

dplyr::**filter(iris, Sepal.Length > 7)**

Permet d'extraire des observations selon une condition logique

dplyr::**distinct(iris)**

Dédoublonne la base

dplyr::**sample_frac(iris, 0.5, replace = TRUE)**

Sélectionne aléatoirement une fraction d'observations

dplyr::**sample_n(iris, 10, replace = TRUE)**

Sélectionne aléatoirement n observations

dplyr::**slice(iris, 10:15)**

Sélectionne les lignes selon leur position

dplyr::**top_n(storms, 2, date)**

Sélectionne et ordonne les n premières observations (ou groupes si les données sont groupées)

Opérateurs logiques dans R - ?Comparison et ?base::Logic

<	Inférieur strictement à	!=	Différent de
>	Supérieur strictement à	%in%	Appartient à
==	Egal à	is.na	Est manquant
<=	Inférieur ou égal à	!is.na	N'est pas manquant
>=	Supérieur ou égal à	&, |, !, xor, any, all	Opérateurs booléens

Extraction de variables (colonnes)

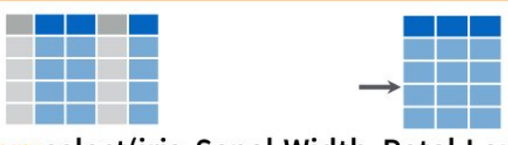

dplyr::**select(iris, Sepal.Width, Petal.Length, Species)**

Selectionne des colonnes selon leur nom ou leur fonction assistantes

Fonctions assistantes à la sélection - ?select

select(iris, contains("."))
Sélectionne les variables contenant la chaîne de caractères **"."**
select(iris, ends_with("Length"))
Sélectionne les variables se terminant par la chaîne de caractères **"Length"**
select(iris, everything())
Sélectionne toutes les variables
select(iris, matches(".t."))
Sélectionne toutes les variables qui correspondent à l' expression régulière **.t.**
select(iris, num_range("x", 1:5))
Sélectionne les variables nommées x1, x2, x3, x4, x5.
select(iris, one_of(c("Species", "Genus")))
Sélectionne les variables dans la liste de noms spécifiée
select(iris, starts_with("Sepal"))
Sélectionne les variables débutant par la chaîne de caractères **"Sepal"**
select(iris, Sepal.Length:Petal.Width)
Sélectionne toutes les variables de Sepal.Length à Petal.Width (incluses).
select(iris, - Species)
Sélectionne toutes les variables sauf *Species*.

Traduit par Diane Beldame • thinkr.fr

Résumer des données

dplyr::**summarise(iris, avg = mean(Sepal.Length))**
Résume de l'information en une seule ligne
dplyr::**summarise_each(iris, funs(mean))**
Applique une fonction (de résumé) sur chaque variable
dplyr::**count(iris, Species, wt = Sepal.Length)**
Dénombre le nombre d'observations de chaque valeur d'une variable (avec ou sans poids)

Summarise utilise des fonctions de résumé qui prennent en entrée un vecteur de valeurs et retournent une seule valeur tel que:

dplyr::**first**
Première valeur d'un vecteur
dplyr::**last**
Dernière valeur d'un vecteur
dplyr::**nth**
N^ième^ valeur d'un vecteur
dplyr::**n**
Nb de valeurs d'un vecteur
dplyr::**n_distinct**
Nb de valeurs distinctes d'un vecteur
IQR
IQR d'un vecteur

min
Valeur minimum d'un vecteur
max
Valeur maximum d'un vecteur
mean
Moyenne d'un vecteur
median
Médiane d'un vecteur
var
Variance d'un vecteur
sd
Ecart-type d'un vecteur

Groupement de données

dplyr::**group_by(iris, Species)**
Regroupe les observations d'iris par la valeur de *Species*.
dplyr::**ungroup(iris)**
Dégroupe le jeu de données

iris %>% group_by(Species) %>% summarise(…)
Construit un *tbl* résumant chaque groupe

Construire de nouvelles variables

dplyr::**mutate(iris, sepal = Sepal.Length + Sepal. Width)**
Calcule et ajoute une ou plusieurs nouvelles variables
dplyr::**mutate_each(iris, funs(min_rank))**
Applique une fonction *window* à chaque variable
dplyr::**transmute(iris, sepal = Sepal.Length + Sepal. Width)**
Construit une ou plusieurs variables en supprimant les originales

Mutate utilise des fonctions window qui prennent en entrée un vecteur et retournent un vecteur tel que:

dplyr::**lead**
Copier avec des valeurs décalées à gauche
dplyr::**lag**
Copier avec des valeurs décalées à droite
dplyr::**dense_rank**
Ordonne sans sauts de rangs
dplyr::**min_rank**
Ordonne avec sauts de rangs
dplyr::**percent_rank**
Rangs de (**min_rank**) entre [0, 1].
dplyr::**row_number**
Ordonne en affectant aux liens la première position.
dplyr::**ntile**
Divise en n groupes.
dplyr::**between**
Les valeurs sont-elles entre a et b?

dplyr::**cume_dist**
Distribution cumulée
dplyr::**cumall**
Cumul tant que vrai
dplyr::**cumany**
Cumul dès que vrai
dplyr::**cummean**
Moyenne glissante
cumsum
Somme cumulée
cummax
Maximum cumulé
cummin
Minimum cumulé
cumprod
Produit cumulé
pmax
Maximum par élément
pmin
Minimum par élément

iris %>% group_by(Species) %>% mutate(…)
Construit de nouvelles variables, par groupe

Fusionner des jeux de données

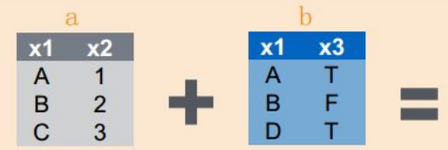

Jointures transformantes

dplyr::**left_join(a, b, by = "x1")**
Joindre à a les variables de b selon x1

dplyr::**right_join(a, b, by = "x1")**
Joindre à b les variables de a selon x1

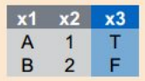

dplyr::**inner_join(a, b, by = "x1")**
Joindre a et b en ne gardant que les observations des deux tableaux

dplyr::**full_join(a, b, by = "x1")**
Joindre a et b en gardant toutes les observations

Jointures filtrantes

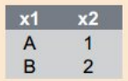

dplyr::**semi_join(a, b, by = "x1")**
Toutes les observations de a ayant des valeurs correspondantes dans b

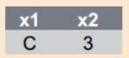

dplyr::**anti_join(a, b, by = "x1")**
Toutes les observations de a n'ayant aucune correspondance dans b.

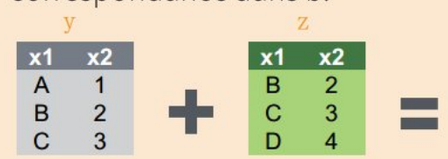

Operations ensemblistes

dplyr::**intersect(y, z)**
Observations appartenant à y et z

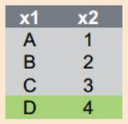

dplyr::**union(y, z)**
Observations appartenant à y et z ou l'un des 2

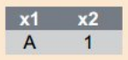

dplyr::**setdiff(y, z)**
Observations appartenant à y et pas à z

Assemblages

dplyr::**bind_rows(y, z)**
Ajoute z à y comme nouvelles lignes.

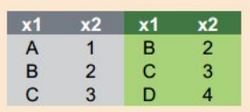

dplyr::**bind_cols(y, z)**
Ajoute z à y comme nouvelles colonnes.
NB: matches rows by position.

devtools::install_github("rstudio/EDAWR") pour les jeux de données