

04 - Types de données et transformations

PRO1036 - Analyse de données scientifiques en R

Tim Bollé

October 6, 2025

Pourquoi s'intéresser aux types de données ?

Example: Cat lovers

Un sondage a demandé à des gens leur nom et le nombre de chat qu'ils possèdent. Les instructions indiquaient d'entrer le nombre de chats en chiffres.

```
1 cat_lovers <- read_csv("data/cat-lovers.csv")
```

```
# A tibble: 60 × 3
```

	name <chr>	number_of_cats <chr>	handedness <chr>
1	Bernice Warren	0	left
2	Woodrow Stone	0	left
3	Willie Bass	1	left
4	Tyrone Estrada	3	left
5	Alex Daniels	3	left
6	Jane Bates	2	left
7	Latoya Simpson	1	left
8	Darin Woods	1	left
9	Agnes Cobb	0	left
10	Tabitha Grant	0	left

```
# i 50 more rows
```

Statistique simple...

```
1 cat_lovers %>%  
2   summarise(mean_cats = mean(number_of_cats))  
  
# A tibble: 1 × 1  
  mean_cats  
    <dbl>  
1         NA
```

Ca ne marche pas...

Pourquoi ?

1 ?mean

mean {base}

R Documentation

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. Complex vectors are 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.

Et maintenant ?

```
1 cat_lovers %>%  
2   summarise(mean_cats = mean(number_of_cats, na.rm = TRUE))  
  
# A tibble: 1 × 1  
  mean_cats  
    <dbl>  
1        NA
```

Toujours pas...

Regardons les données

```
1 glimpse(cat_lovers)
```

Rows: 60

Columns: 3

```
$ name      <chr> "Bernice Warren", "Woodrow Stone", "Willie Bass", "Tyro...  
$ number_of_cats <chr> "0", "0", "1", "3", "3", "2", "1", "1", "0", "0", "0", ...  
$ handedness  <chr> "left", "left", "left", "left", "left", "left", "left", "left",...
```

Il suffit de convertir !

```

1 cat_lovers %>%
2   mutate(
3     number_of_cats = as.numeric(number_of_cats)
4   ) %>%
5   summarise(mean_cats = mean(number_of_cats, na.rm = TRUE))

# A tibble: 1 × 1
  mean_cats
  <dbl>
1    0.776

```

Ok mais ...

Warning: There was 1 warning in `mutate()`.

- In argument: `number\_of\_cats = as.numeric(number\_of\_cats)`.

Caused by warning:

- ! NAs introduits lors de la conversion automatique

Regardons cela de plus près...

Show

10

 entries

Search:

	name	◆ number_of_cats	◆ handedness ◆
1	Bernice Warren	0	left
2	Woodrow Stone	0	left
3	Willie Bass	1	left
4	Tyrone Estrada	3	left
5	Alex Daniels	3	left
6	Jane Bates	2	left
7	Latoya Simpson	1	left
8	Darin Woods	1	left
9	Agnes Cobb	0	left
10	Tabitha Grant	0	left

Showing 1 to 10 of 60 entries

Respecter les types de données

```
1 cat_lovers %>%
2   mutate(
3     number_of_cats = case_when(
4       name == "Ginger Clark" ~ "2",
5       name == "Doug Bass"   ~ "3",
6       TRUE                  ~ number_of_cats
7     ),
8     number_of_cats = as.numeric(number_of_cats)
9   ) %>%
10  summarise(mean_cats = mean(number_of_cats))
```

```
# A tibble: 1 × 1
  mean_cats
  <dbl>
1    0.833
```

Enregistrer

```
1 cat_lovers <- cat_lovers %>%
2   mutate(
3     number_of_cats = case_when(
4       name == "Ginger Clark" ~ "2",
5       name == "Doug Bass"   ~ "3",
6       TRUE                  ~ number_of_cats
7     ),
8     number_of_cats = as.numeric(number_of_cats)
9   )
```

Morale

- Si vos données ne se comportent pas comme vous l'attendez, il se peut qu'il s'agisse d'un problème de type de données.
- Explorez et investiguez vos données, appliquez les modifications, *sauvegardez vos données*, vivez heureux

Types de données

Types de données dans R

- logical
- double
- integer
- character
- Il y a en d'autres mais nous les utiliserons peu

Logical et character

logical - Valeurs booléennes TRUE et FALSE

```
1 typeof(TRUE)
[1] "logical"
```

character - Texte

```
1 typeof("Hello")
[1] "character"
```

Double et integer

double - Nombres à virgule flottante (type par défaut pour les nombres)

```
1  typeof(1.5)
```

```
[1] "double"
```

```
1  typeof(7)
```

```
[1] "double"
```

integer - Nombres entiers (indiqué par un L)

```
1  typeof(1L)
```

```
[1] "integer"
```

```
1  typeof(1:3)
```

```
[1] "integer"
```

Concatenation

Des vecteurs peuvent être construits à l'aide de la fonction `c()`

```
1 c(1, 2, 3)
```

```
[1] 1 2 3
```

```
1 c("Hello", "World!")
```

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

```
1 c(c("hi", "hello"), c("bye", "jello"))
```

```
[1] "hi"      "hello" "bye"     "jello"
```

Conversion

... intentionnelle

```
1 x <- 1:3
2 x
[1] 1 2 3
```

```
1 typeof(x)
[1] "integer"
```

```
1 x <- c(TRUE, FALSE)
2 x
[1] TRUE FALSE
```

```
1 typeof(x)
[1] "logical"
```

```
1 y <- as.character(x)
2 y
[1] "1" "2" "3"
```

```
1 typeof(y)
[1] "character"
```

```
1 y <- as.numeric(x)
2 y
[1] 1 0
```

```
1 typeof(y)
[1] "double"
```

Conversion

... accidentelle

R va faire les conversions sans se poser de questions, surtout quand on mets différentes choses dans un même vecteur.

```
1 c(1, "Hello")
[1] "1"      "Hello"
```

```
1 c(FALSE, 3L)
[1] 0 3
```

```
1 c(1.2, 3L)
[1] 1.2 3.0
```

```
1 c(2L, "two")
[1] "2"      "two"
```

Conversion

- **Explicite** - Utilisez les fonctions `as.*()`
 - `as.logical()`
 - `as.numeric()`
 - `as.integer()`
 - `as.character()`
 - `as.double()`
- **Implicite** - R va faire les conversions pour vous, soyez vigilant

Cas spéciaux

Cas spéciaux

- NA - Valeur manquante
- Inf - Infini
- NaN - Not a Number

```
1 # division par zéro -> Inf
2 7/0
[1] Inf
```

```
1 -1/0
[1] -Inf
```

```
1 Inf - Inf
[1] NaN
```

NA

```
1 x <- c(1, 2, 3, 4, NA)
1 mean(x)
```

```
[1] NA
```

```
1 mean(x, na.rm = TRUE)
```

```
[1] 2.5
```

```
1 summary(x)
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	NA's
1.00	1.75	2.50	2.50	3.25	4.00	1

NA

Les **NA** sont utilisés par R pour représenter des valeurs manquantes. Ils sont de type logique.

```
1 typeof(NA)
[1] "logical"
```

```
1 # TRUE or NA
2 TRUE | NA
[1] TRUE
```

```
1 # FALSE or NA
2 FALSE | NA
[1] NA
```

Classes de données

Classes de données

Nous avons parlé des *types* des données et nous allons maintenant parler des *classes* des données:

- Vecteurs sont comme des briques LEGO
- On les colle ensemble pour construire des structures plus compliquées, notamment des *représentations de données*

Par exemples:

- factor
- date
- data frame

factor

Les facteurs sont utilisés pour gérer les variables catégorielles, c'est-à-dire les variables qui ont un ensemble fixe et connu de valeurs possibles.

```
1 x <- factor(c("BS", "MS", "PhD", "MS"))  
2 x
```

```
[1] BS  MS  PhD MS  
Levels: BS MS PhD
```

```
1 typeof(x)
```

```
[1] "integer"
```

```
1 class(x)
```

```
[1] "factor"
```

factor

Pour chaque facteur on a:

- `levels` - Les valeurs possibles
- `labels` - Les étiquettes associées aux valeurs

```
1 glimpse(x)
Factor w/ 3 levels "BS","MS","PhD": 1 2 3 2
1 as.integer(x)
[1] 1 2 3 2
```

Dates

```
1 y <- as.Date("2024-01-01")  
2 y
```

```
[1] "2024-01-01"
```

```
1 typeof(y)
```

```
[1] "double"
```

```
1 class(y)
```

```
[1] "Date"
```

Dates

Les dates sont en réalité un entier (le nombre de jours depuis l'origine, 1 Jan 1970) et un entier (l'origine) collés ensemble

```
1 as.integer(y)
```

```
[1] 19723
```

```
1 as.integer(y) / 365
```

```
[1] 54.03562
```

Data frames

Les data frames sont des structures de données qui sont comme des vecteurs de différentes classes.

```
1 df <- data.frame(x = 1:2, y = 3:4)
2 df
```

```
  x y
1 1 3
2 2 4
```

```
1 typeof(df)
```

```
[1] "list"
```

```
1 class(df)
```

```
[1] "data.frame"
```

Listes

Les listes sont des conteneurs génériques pour des vecteurs de n'importe quel type.

```
1 l <- list(  
2   x = 1:4,  
3   y = c("hi", "hello", "jello"),  
4   z = c(TRUE, FALSE)  
5 )  
6 l
```

```
$x  
[1] 1 2 3 4
```

```
$y  
[1] "hi"      "hello" "jello"
```

```
$z  
[1] TRUE FALSE
```

Listes et data frames

- Un data frame est une liste spéciale contenant des vecteurs de longueur égale
- Un **tibble** est un data frame du Tidyverse

```

1 df
  x y
1 1 3
2 2 4

1 df %>%
2   as_tibble()


# A tibble: 2 × 2
  x     y
<int> <int>
1     1     3
2     2     4

1 df %>%
2   as_tibble() %>%
3   class()

[1] "tbl_df"      "tbl"        "data.frame"
```

Tibbles

Les Tibbles sont des data frames modernes. Ils sont adaptés au tidyverse (en pratique, toutes les fonctions du tidyverse retournent des **tibbles** au lieu de **data.frame**).



- Les tibbles ont un affichage limité, adapté à la console
- Il est possible d'accéder à une colonne à l'aide des double crochets (`df[["x"]]`) en plus du `$` (`df$x`). Il est ainsi possible d'utiliser le numéro de colonne au lieu du nom (`df[[1]]`)
- Les tibbles fournissent également plus d'indications lorsque quelque chose ne va pas (messages de *warnings*).

Travailler avec des facteurs

Exemple: Cat lovers

Nous commençons avec un data frame avec des caractères

```
1 glimpse(cat_lovers)
```

Rows: 60

Columns: 3

\$ name <chr> "Bernice Warren", "Woodrow Stone", "Willie Bass", "Tyro...

\$ number_of_cats <chr> "0", "0", "1", "3", "3", "2", "1", "1", "0", "0", "0", ...


\$ handedness <chr> "left", "left", "left", "left", "left", "left", "left", "left", ...

Plotting

Au moment de faire un graphique, R va faire une conversion de type

Si on lui demande de plotter des catégories, il va créer des facteurs


```
1 ggplot(cat_lovers, mapping = aes(x = handedness)) +  
2   geom_bar()
```



Les facteurs sont ordonnées par ordre alphabétique par défaut


On peut manipuler les facteurs avec **forcats**

```
1 cat_lovers %>%  
2   mutate(handedness = fct_infreq(handedness)) %>%  
3   ggplot(mapping = aes(x = handedness)) +  
4   geom_bar()
```



La grammaire de la manipulation de données

Basé sur des fonctions qui correspondent à des verbes permettant de manipuler des dataframes.



- Les facteurs sont utiles lorsque vous avez des données catégorielles et que vous voulez remplacer l'ordre des vecteurs de caractères pour améliorer l'affichage
- Le package **forcats** fournit une suite d'outils utiles qui résolvent des problèmes courants avec les facteurs


Les fonctions de **forcats**

focats possède plusieurs fonctions pour manipuler les facteurs:

- `fct_reorder()` - Réordonne les niveaux d'un facteur en fonction d'une autre variable
- `fct_relevel()` - Réordonne les niveaux d'un facteur
- `fct_infreq()` - Réordonne les niveaux d'un facteur en fonction de leur fréquence
- `fct_lump()` - Regroupe les niveaux d'un facteur en "autres"
- `fct_explicit_na()` - Ajoute un niveau pour les valeurs manquantes


Example: starwars

```
1 starwars %>%  
2   ggplot(aes(y = hair_color)) +  
3   geom_bar()
```



Ordre selon la fréquence : `fct_infreq()`

```
1 starwars %>%
2   mutate(
3     hair_color = fct_infreq(hair_color)
4   ) %>%
5   ggplot(aes(y = hair_color)) +
6   geom_bar()
```



Regroupement de facteurs

Utile quand on a beaucoup de niveaux

```
1 starwars %>%
2   count(skin_color, sort = TRUE)
```

A tibble: 31 × 2

	skin_color	n
	<chr>	<int>
1	fair	17
2	light	11
3	dark	6
4	green	6
5	grey	6
6	pale	5
7	brown	4
8	blue	2
9	blue, grey	2
10	none	2

i 21 more rows

... 31 niveaux dans cet exemple !

Regroupement de facteurs : `fct_lump()`

```
1 starwars %>%
2   mutate(skin_color = fct_lump(skin_color, n = 5)) %>%
3   count(skin_color, sort = TRUE)
```


A tibble: 6 × 2

	skin_color	n
	<fct>	<int>
1	Other	41
2	fair	17
3	light	11
4	dark	6
5	green	6
6	grey	6

Regroupement de facteurs

Regardons maintenant la masse moyenne selon la couleur des yeux:


```
1 starwars %>%
2   mutate(eye_color = fct_lump(eye_color, n = 6)) %>%
3   group_by(eye_color) %>%
4   summarise(mean_mass = mean(mass, na.rm = TRUE)) %>%
5   ggplot(aes(x = eye_color, y = mean_mass)) +
6   geom_col()
```



Regroupement et changement d'ordre !

Nous allons maintenant regrouper les couleurs des yeux et les ordonner selon la masse moyenne


```
1 starwars %>%
2   mutate(eye_color = fct_lump(eye_color, n = 6)) %>%
3   group_by(eye_color) %>%
4   summarise(mean_mass = mean(mass, na.rm = TRUE)) %>%
5   mutate(eye_color = fct_reorder(eye_color, mean_mass)) %>%
6   ggplot(aes(x = eye_color, y = mean_mass)) +
7   geom_col()
```



Example: Hotels

Comparison of resort and city hotel prices across months


Resort hotel prices soar in the summer while city hotel prices remain relatively constant throughout the year



Example: Hotels

Comparison of resort and city hotel prices across months

Resort hotel prices soar in the summer while city hotel prices remain relatively constant throughout the year



Choix manuel de l'ordre : `fct_relevel()`

La variable `month.name` est une variable intégrée dans R qui contient les noms des mois en anglais et dans le bon ordre.

```


1 hotels <- readr::read_csv("data/hotels.csv")
2
3 hotels %>%
4   mutate(arrival_date_month = fct_relevel(arrival_date_month, month.name)) %>% # On réord
5   group_by(hotel, arrival_date_month) %>% # group by type d'hotel et mois d'arrivée
6   summarise(mean_adr = mean(adr)) %>% # calcul de l'ADR moyen pour chaque groupe
7   ggplot(aes(
8     x = arrival_date_month,
9     y = mean_adr, # mean_adr sur y-axis
10    group = hotel, # Groupe les lignes par type
11    color = hotel) # couleur par type
12  ) +
13  geom_line() + # On veut des lignes
14  scale_y_continuous(labels = label_dollar()) +
15  theme_minimal() + # Utilise le minimal theme
16  labs(x = "Arrival month", # On met à jour les labels
17       y = "Mean ADR (average daily rate)",
18       title = "Comparison of resort and city hotel prices across months",
19       subtitle = "Resort hotel prices soar in the summer while city hotel prices remain\:",
20       color = "Hotel type") +
21  scale_x_discrete(guide = guide_axis(check.overlap = TRUE)) # On s'assure que les labels

```

Renommer les niveaux : `fct_recode()`

Si on veut simplement renommer les niveaux, on peut utiliser `fct_recode()`

```
1 cat_lovers %>%
2   mutate(handedness = fct_recode(handedness, gaucher = "left", droitier = "right")) %>%
3   mutate(handedness = fct_infreq(handedness)) %>%
4   ggplot(mapping = aes(x = handedness)) +
5   geom_bar()
```



Travailler avec les dates

Dates



- **lubridate** est un package tidyverse-friendly qui facilite la manipulation des dates
- Il ne fait pas partie du coeur tidyverse, donc il doit être installé avec `install.packages("lubridate")` mais il n'est pas chargé avec lui, et doit être explicitement chargé avec `library(lubridate)`.

■ ...



Exemple des hotels

Calculer et visualiser le nombre de réservations à une date d'arrivée donnée

Nous allons voir les bases mais travailler avec des dates peut s'avérer complexe mais cela peut apporter beaucoup à une analyse.

Show entries

Search:

	hotel	is_canceled	lead_time	arrival_date_year	arrival_date_month	arrival_date_week_number
1	Resort Hotel	0	342	2015	July	27
2	Resort Hotel	0	737	2015	July	27
3	Resort Hotel	0	7	2015	July	27

Showing 1 to 3 of 3 entries

Previous

1

Next

Étape 1 - Construire la date

```
1 library(glue) # glue permet de coller des éléments ensemble
2
3 hotels %>%
4   mutate(
5     arrival_date = glue("{arrival_date_year} {arrival_date_month} {arrival_date_day_of_mo:
6   ) %>%
7   relocate(arrival_date) # pour afficher la nouvelle colonne à gauche
```

A tibble: 119,390 × 33

	arrival_date	hotel	is_canceled	lead_time	arrival_date_year	arrival_date_month
	<glue>	<chr>	<dbl>	<dbl>	<dbl>	<chr>
1	2015 July 1	Reso...	0	342	2015	July
2	2015 July 1	Reso...	0	737	2015	July
3	2015 July 1	Reso...	0	7	2015	July
4	2015 July 1	Reso...	0	13	2015	July
5	2015 July 1	Reso...	0	14	2015	July
6	2015 July 1	Reso...	0	14	2015	July
7	2015 July 1	Reso...	0	0	2015	July
8	2015 July 1	Reso...	0	9	2015	July
9	2015 July 1	Reso...	1	85	2015	July
10	2015 July 1	Reso...	1	75	2015	July

i 119,380 more rows

i 27 more variables: arrival_date_week_number <dbl>,
 # arrival_date_day_of_month <dbl>, stays_in_weekend_nights <dbl>,
 # stays_in_week_nights <dbl>, adults <dbl>, children <dbl>, babies <dbl>,
 # meal <chr>, country <chr>, market_segment <chr>,
 # distribution_channel <chr>, is_repeated_guest <dbl>,
 # previous_cancellations <dbl>, previous_bookings_not_canceled <dbl>, ...


Étape 2 - Compter les réservations par dates

```
1 hotels %>%
2   mutate(arrival_date = glue("{arrival_date_year} {arrival_date_month} {arrival_date_day_")
3   count(arrival_date)
```

```
# A tibble: 793 × 2
  arrival_date      n
  <glue>          <int>
1 2015 August 1      110
2 2015 August 10     207
3 2015 August 11     117
4 2015 August 12     133
5 2015 August 13     107
6 2015 August 14     329
7 2015 August 15     190
8 2015 August 16       98
9 2015 August 17     188
10 2015 August 18       94
# i 783 more rows
```

Étape 4 - Visualiser

```
1 hotels %>%
2   mutate(arrival_date = glue("{arrival_date_year} {arrival_date_month} {arrival_date_day_")
3   count(arrival_date) %>%
4   ggplot(aes(x = arrival_date, y = n, group = 1)) +
5   geom_line()
```



Quel est le problème ici ?

Étape 1 - Construire la date (comme une date)

```

1 library(lubridate) # pour les dates
2
3 hotels %>%
4   mutate(
5     arrival_date = ymd(glue("{arrival_date_year} {arrival_date_month} {arrival_date_day_o
6   }) %>%
7   relocate(arrival_date)

```

```

# A tibble: 119,390 × 33
  arrival_date hotel is_canceled lead_time arrival_date_year arrival_date_month
  <date>         <chr>         <dbl>     <dbl>         <dbl> <chr>
1 2015-07-01    Reso...             0       342         2015 July
2 2015-07-01    Reso...             0       737         2015 July
3 2015-07-01    Reso...             0         7         2015 July
4 2015-07-01    Reso...             0        13         2015 July
5 2015-07-01    Reso...             0        14         2015 July
6 2015-07-01    Reso...             0        14         2015 July
7 2015-07-01    Reso...             0         0         2015 July
8 2015-07-01    Reso...             0         9         2015 July
9 2015-07-01    Reso...             1        85         2015 July
10 2015-07-01    Reso...             1        75         2015 July
# i 119,380 more rows
# i 27 more variables: arrival_date_week_number <dbl>,
# arrival_date_day_of_month <dbl>, stays_in_weekend_nights <dbl>,
# stays_in_week_nights <dbl>, adults <dbl>, children <dbl>, babies <dbl>,
# meal <chr>, country <chr>, market_segment <chr>,
# distribution_channel <chr>, is_repeated_guest <dbl>,
# previous_cancellations <dbl>, previous_bookings_not_canceled <dbl>, ...

```

Étape 2 - Compter les réservations par dates

```
1 hotels %>%
2   mutate(arrival_date = ymd(glue("{arrival_date_year} {arrival_date_month} {arrival_date_day}"))
3   count(arrival_date)
```


```
# A tibble: 793 × 2
  arrival_date      n
  <date>         <int>
1 2015-07-01      122
2 2015-07-02       93
3 2015-07-03       56
4 2015-07-04       88
5 2015-07-05       53
6 2015-07-06       75
7 2015-07-07       54
8 2015-07-08       69
9 2015-07-09       80
10 2015-07-10       51
# i 783 more rows
```

Étape 3a - Visualiser

```

1 hotels %>%
2   mutate(arrival_date = ymd(glue("{arrival_date_year} {arrival_date_month} {arrival_date_day}"))
3   count(arrival_date) %>%
4   ggplot(aes(x = arrival_date, y = n, group = 1)) +
5   geom_line()

```



Étape 3b - Visualiser avec une courbe

```

1 hotels %>%
2   mutate(arrival_date = ymd(glue("{arrival_date_year} {arrival_date_month} {arrival_date_day}"))
3   count(arrival_date) %>%
4   ggplot(aes(x = arrival_date, y = n, group = 1)) +
5   geom_smooth() #<<

```

