Manipuler des bases de données avec `dplyr`

```
gapminder
```

```
##                 country continent year lifeExp      pop  gdpPercap
## 1           Afghanistan      Asia 1952  28.801  8425333   779.4453
## 2           Afghanistan      Asia 1957  30.332  9240934   820.8530
## 3           Afghanistan      Asia 1962  31.997 10267083   853.1007
## 4           Afghanistan      Asia 1967  34.020 11537966   836.1971
## 5           Afghanistan      Asia 1972  36.088 13079460   739.9811
## 6           Afghanistan      Asia 1977  38.438 14880372   786.1134
## 7           Afghanistan      Asia 1982  39.854 12881816   978.0114
## 8           Afghanistan      Asia 1987  40.822 13867957   852.3959
## 9           Afghanistan      Asia 1992  41.674 16317921   649.3414
## 10          Afghanistan      Asia 1997  41.763 22227415   635.3414
## 11          Afghanistan      Asia 2002  42.129 25268405   726.7341
## 12          Afghanistan      Asia 2007  43.828 31889923   974.5803
## 13              Albania    Europe 1952  55.230  1282697  1601.0561
## 14              Albania    Europe 1957  59.280  1476505  1942.2842
## 15              Albania    Europe 1962  64.820  1728137  2312.8890
## 16              Albania    Europe 1967  66.220  1984060  2760.1969
```

tidyverse

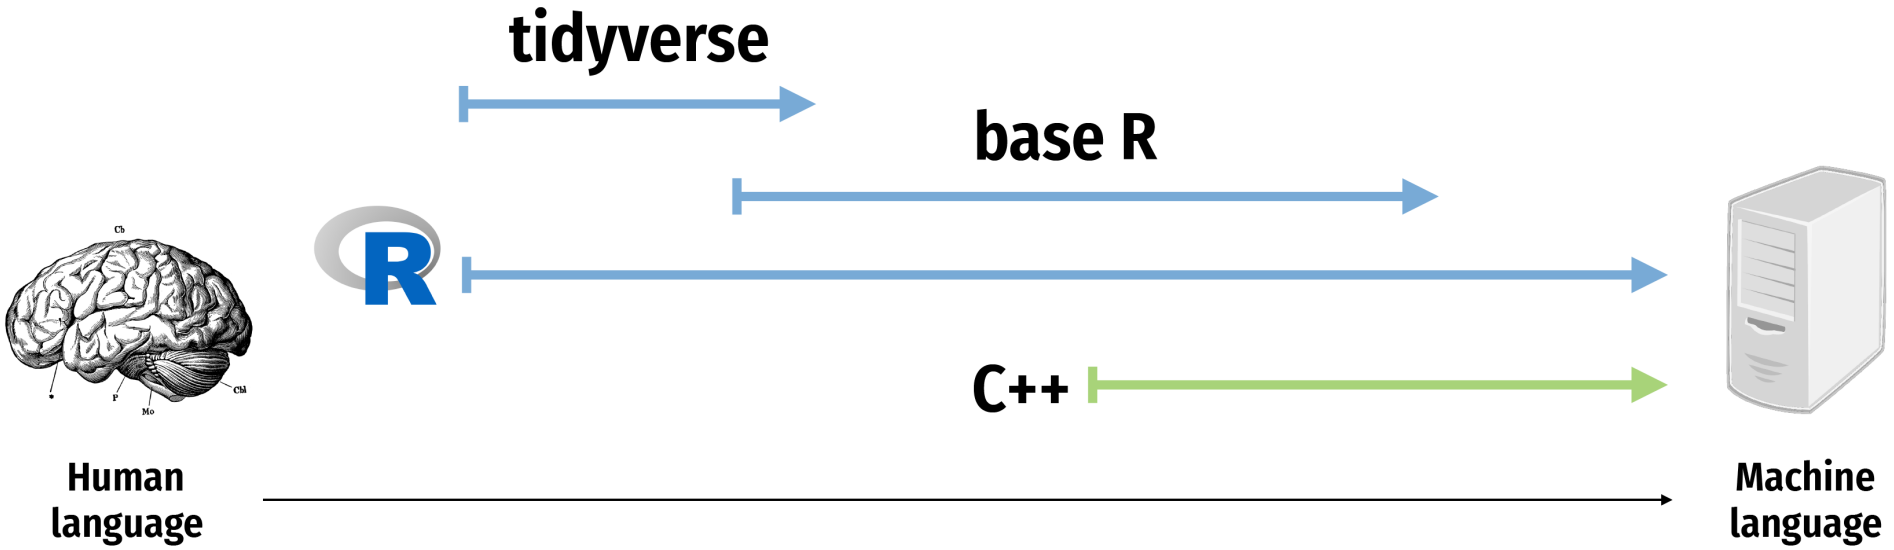

tidyverse

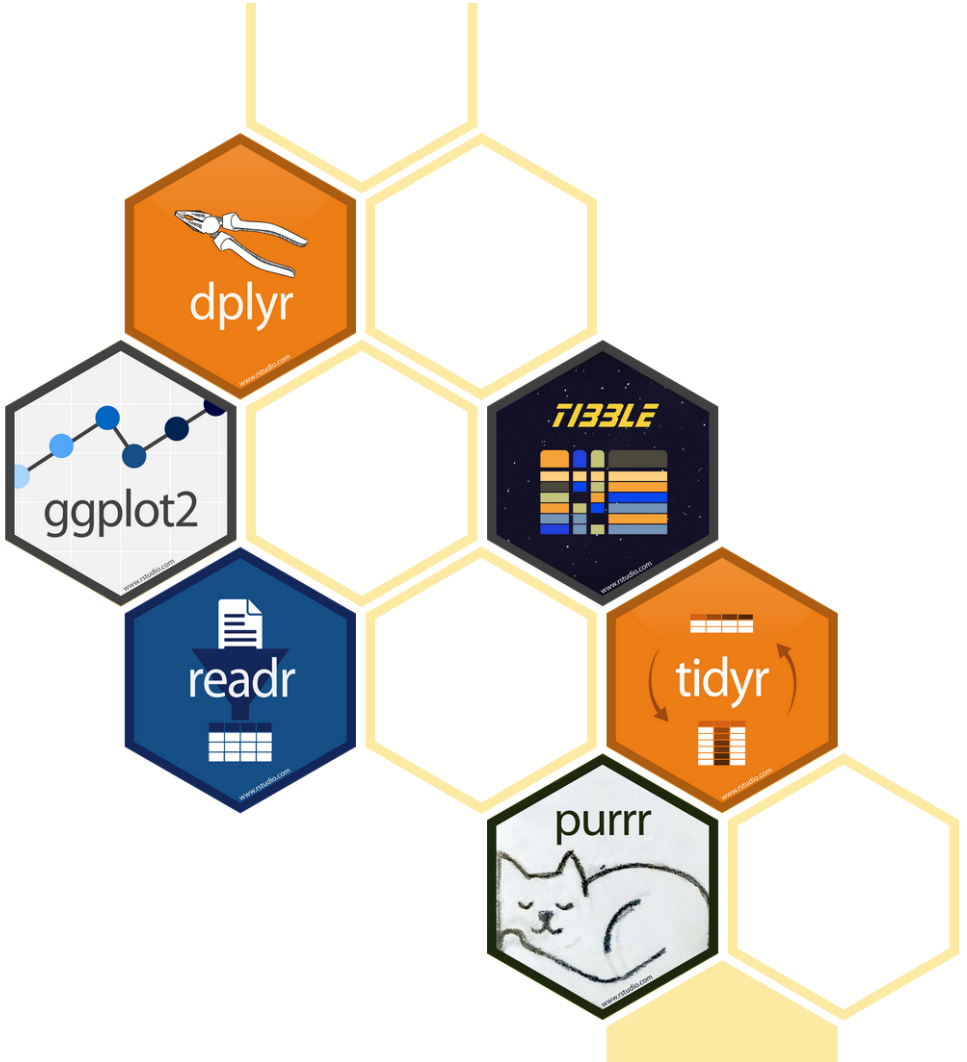

`dplyr`: verbes pour manipuler des données

Extraire des lignes avec `filter()`

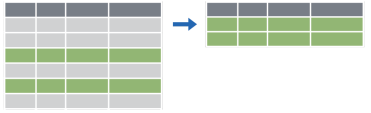

Extraire des colonnes avec `select()`

Arranger/trier les lignes avec `arrange()`

Créer/modifier des colonnes avec `mutate()`

Résumer des sous-ensembles avec `group_by() |> summarize()`

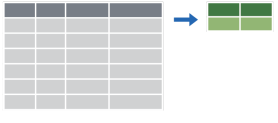

filter()

filter()

Extraire des lignes selon une condition logique

```
filter(.data = DATA, ...)
```

- **DATA** = tableau de données à transformer
- **...** = Un ou plusieurs tests

`filter()` retourne chaque ligne pour lequel le test retourne `TRUE`

```
filter(.data = gapminder, country == "Denmark")
```

country	continent	year
Afghanistan	Asia	1952
Afghanistan	Asia	1957
Afghanistan	Asia	1962
Afghanistan	Asia	1967
Afghanistan	Asia	1972
...	...	...

country	continent	year
Denmark	Europe	1952
Denmark	Europe	1957
Denmark	Europe	1962
Denmark	Europe	1967
Denmark	Europe	1972
Denmark	Europe	1977

filter()

```
filter(.data = gapminder,
       country == "Denmark")
```

Un signe =
pour l'assignation d'un argument

Deux signes ==
teste l'égalité entre objets
(retourne TRUE ou FALSE)

Tests logiques

Test	Signification	Test	Signification
`x < y`	plus petit que	`x %in% y`	dans (élément d'un vecteur)
`x > y`	plus grand que	`is.na(x)`	valeur manquante?
`==`	égale	`!is.na(x)`	valeurs non manquantes
`x <= y`	plus petit ou égal à		
`x >= y`	plus grand ou égal à		
`x != y`	différent de		

À votre tour #1: filtrer

Utilisez `filter()` et des tests logiques pour montrer...

1. Les données du Canada
2. Toutes les données de pays situés en Océanie (Oceania)
3. Lignes où l'espérance de vie est supérieure à 82 ans

03:00

```
filter(gapminder, country == "Canada")
```

```
filter(gapminder, continent == "Oceania")
```

```
filter(gapminder, lifeExp > 82)
```

Erreur fréquente

Utiliser = plutôt que ==

```
filter(gapminder,
       country = "Canada")
```

```
filter(gapminder,
       country == "Canada")
```

Mettre entre accolade

```
filter(gapminder,
       country == Canada)
```

```
filter(gapminder,
       country == "Canada")
```

`filter()` avec des conditions multiples

Extrait les lignes qui valident *tous* les énoncés

```
filter(gapminder, country == "Denmark", year > 2000)
```

```
filter(gapminder, country == "Denmark", year > 2000)
```

country	continent	year
Afghanistan	Asia	1952
Afghanistan	Asia	1957
Afghanistan	Asia	1962
Afghanistan	Asia	1967
Afghanistan	Asia	1972
...	...	...

country	continent	year
Denmark	Europe	2002
Denmark	Europe	2007

Opérateurs logiques

Opérateur	Signification
`a & b`	et
`a | b`	ou
`!a`	pas

Par défaut, union ("et")

Commandes équivalentes

```
filter(gapminder, country == "Denmark", year > 2000)
```

```
filter(gapminder, country == "Denmark" & year > 2000)
```

À votre tour #2: filtrer

Utilisez `filter()` et les opérateurs logiques pour montrer...

1. Les données du Canada avant 1970
2. Les pays où l'espérance de vie en 2007 est inférieure à 50
3. Les pays hors d'Afrique où l'espérance de vie en 2007 est inférieur à 50

04:00

```
filter(gapminder, country == "Canada", year < 1970)
```

```
filter(gapminder, year == 2007, lifeExp < 50)
```

```
filter(gapminder, year == 2007, lifeExp < 50,
       continent != "Africa")
```

Erreurs fréquentes

Rassembler plusieurs conditions en une seule

```
filter(gapminder, 1960 < year < 1980)
```

```
filter(gapminder,
       year > 1960, year < 1980)
```

Utiliser plusieurs tests plutôt que `%in%`

```
filter(gapminder,
       country == "Mexico",
       country == "Canada",
       country == "United States")
```

```
filter(gapminder,
       country %in% c("Mexico", "Canada",
                      "United States"))
```

Syntaxe commune

Chaque verbe de `dplyr` a la même syntaxe

Base de données comme premier argument, retourne une base de données

```
VERB(DATA, ...)
```

- **`VERB`** = fonction `dplyr`/verbe
- **`DATA`** = base de données à transformer
- **`...`** = commandes pour le verbe

mutate()

Créer de nouvelles colonnes

```
mutate(.data, ...)
```

- **`.data`** = base de données à transformer
- **`...`** = colonnes à modifier/créer

```
mutate(gapminder, gdp = gdpPercap * pop)
```

country	year	gdpPercap	pop
Afghanistan	1952	779.4453145	8425333
Afghanistan	1957	820.8530296	9240934
Afghanistan	1962	853.10071	10267083
Afghanistan	1967	836.1971382	11537966
Afghanistan	1972	739.9811058	13079460
...	...	...	...

country	year	...	gdp
Afghanistan	1952	...	6567086330
Afghanistan	1957	...	7585448670
Afghanistan	1962	...	8758855797
Afghanistan	1967	...	9648014150
Afghanistan	1972	...	9678553274
Afghanistan	1977	...	11697659231

```
mutate(gapminder, gdp = gdpPercap * pop,
                  pop_mil = round(pop / 1000000))
```

country	year	gdpPercap	pop
Afghanistan	1952	779.4453145	8425333
Afghanistan	1957	820.8530296	9240934
Afghanistan	1962	853.10071	10267083
Afghanistan	1967	836.1971382	11537966
Afghanistan	1972	739.9811058	13079460
...	...	...	...

country	year	...	gdp	pop_mil
Afghanistan	1952	...	6567086330	8
Afghanistan	1957	...	7585448670	9
Afghanistan	1962	...	8758855797	10
Afghanistan	1967	...	9648014150	12
Afghanistan	1972	...	9678553274	13
Afghanistan	1977	...	11697659231	15

ifelse()

Effectuer des tests conditionnels

```
ifelse(TEST,
       VALEUR_SI_VRAI,
       VALEUR_SI_FAUX)
```

- **TEST** = un test logique
- **VALEUR_SI_VRAI** = valeur si vrai
- **VALEUR_SI_FAUX** = valeur si faux

Vecteur en sortie de la même longueur que TEST

```
mutate(gapminder,
       after_1960 = year > 1960)
```

```
mutate(gapminder,
       after_1960 = ifelse(year > 1960,
                           "After 1960",
                           "Before 1960"))
```

```
mutate(gapminder,
       after_1960 = year > 1960)
```

```
##         country continent year lifeExp      pop  gdpPercap after_1960
## 1   Afghanistan      Asia 1952  28.801  8425333   779.4453      FALSE
## 2   Afghanistan      Asia 1957  30.332  9240934   820.8530      FALSE
## 3   Afghanistan      Asia 1962  31.997 10267083   853.1007       TRUE
## 4   Afghanistan      Asia 1967  34.020 11537966   836.1971       TRUE
## 5   Afghanistan      Asia 1972  36.088 13079460   739.9811       TRUE
## 6   Afghanistan      Asia 1977  38.438 14880372   786.1134       TRUE
## 7   Afghanistan      Asia 1982  39.854 12881816   978.0114       TRUE
## 8   Afghanistan      Asia 1987  40.822 13867957   852.3959       TRUE
## 9   Afghanistan      Asia 1992  41.674 16317921   649.3414       TRUE
## 10  Afghanistan      Asia 1997  41.763 22227415   635.3414       TRUE
## 11  Afghanistan      Asia 2002  42.129 25268405   726.7341       TRUE
## 12  Afghanistan      Asia 2007  43.828 31889923   974.5803       TRUE
## 13      Albania    Europe 1952  55.230  1282697  1601.0561      FALSE
## 14      Albania    Europe 1957  59.280  1476505  1942.2842      FALSE
```

case_when()

Tests conditionnels vectorisés

```
case_when(CAS1_EST_VRAI ~ VALEUR1,
          CAS2_EST_VRAI ~ VALEUR2,
          TRUE ~ VALEUR_AUTRE)
```

Énoncés évalués si les précédents ne sont pas vrais.

Retourne NA pour toute valeur restante si on omet le dernier énoncé

```
mutate(gapminder,
       decennie = case_when(
         year < 1960 ~ "années 50",
         year >= 1960 & year < 1970 ~ "années 60",
         year >= 1970 & year < 1980 ~ "années 70",
         year >= 1980 & year < 1990 ~ "années 80",
         year >= 1990 & year < 2000 ~ "années 90",
         TRUE ~ "millénaire")
)
```

```
##       country continent year lifeExp      pop  gdpPercap   decennie
## 1   Afghanistan      Asia 1952  28.801  8425333   779.4453  années 50
## 2   Afghanistan      Asia 1957  30.332  9240934   820.8530  années 50
## 3   Afghanistan      Asia 1962  31.997 10267083   853.1007  années 60
## 4   Afghanistan      Asia 1967  34.020 11537966   836.1971  années 60
## 5   Afghanistan      Asia 1972  36.088 13079460   739.9811  années 70
## 6   Afghanistan      Asia 1977  38.438 14880372   786.1134  années 70
## 7   Afghanistan      Asia 1982  39.854 12881816   978.0114  années 80
## 8   Afghanistan      Asia 1987  40.822 13867957   852.3959  années 80
## 9   Afghanistan      Asia 1992  41.674 16317921   649.3414  années 90
## 10  Afghanistan      Asia 1997  41.763 22227415   635.3414  années 90
## 11  Afghanistan      Asia 2002  42.129 25268405   726.7341 millénaire
## 12  Afghanistan      Asia 2007  43.828 31889923   974.5803 millénaire
## 13      Albania    Europe 1952  55.230  1282697  1601.0561  années 50
## 14      Albania    Europe 1957  59.280  1476505  1942.2842  années 50
## 15      Albania    Europe 1962  64.820  1728137  2312.8890  années 60
## 16      Albania    Europe 1967  66.220  1984060  2760.1969  années 60
## 17      Albania    Europe 1972  67.690  2263554  3313.4222  années 70
## 18      Albania    Europe 1977  68.930  2509048  3533.0039  années 70
```

À votre tour #3: transformer

Utilisez `mutate()` pour ajouter les colonnes...

1. `africa`, qui est vrai (`TRUE`) si le pays est situé sur le continent africain
2. `log_gdpPercap` pour le log PIB par capita (indice: utiliser `log()`)
3. `africa_asia` avec comme valeur `"Afrique ou Asie"` si le pays est dans un des deux continents, sinon `"Autre continent"`

05:00

```
mutate(gapminder,
       africa = continent == "Africa")
```

```
mutate(gapminder,
       log_gdpPercap = log(gdpPercap))
```

```
mutate(gapminder,
       africa_asia = ifelse(continent %in% c("Africa", "Asia"),
                            "Afrique ou Asie",
                            "Autre continent"))
```

Comment procéder avec plusieurs verbes?

Créer un jeu de données pour 2002 *et* calculer le log PIB par capita

Solution 1: variables auxiliaires

```
gapminder_2002 <- filter(gapminder, year == 2002)

gapminder_2002_log <- mutate(gapminder_2002,
                             log_gdpPercap = log(gdpPercap))
```

Comment procéder avec plusieurs verbes?

Créer un jeu de données pour 2002 *et* calculer le log PIB par capita

Solution 2: fonctions emboîtées

```
filter(mutate(gapminder,
              log_gdpPercap = log(gdpPercap)),
       year == 2002)
```

Comment procéder avec plusieurs verbes?

Créer un jeu de données pour 2002 *et* calculer le log PIB par capita

Solution 3: tuyaux!

L'opérateur tuyau, `|>`, prend un objet à gauche et l'assigne au premier argument de la fonction de droite

```
gapminder |> filter(_, country == "Canada")
```

Comment procéder avec plusieurs verbes?

Ces deux lignes donnent le même résultat

```
filter(gapminder, country == "Canada")
```

```
gapminder |> filter(country == "Canada")
```

Comment procéder avec plusieurs verbes?

Créer un jeu de données pour 2002 *et* calculer le log PIB par capita

Solution 3: Tuyaux!

```
gapminder |>
  filter(year == 2002) |>
  mutate(log_gdpPercap = log(gdpPercap))
```

Améliorer la lisibilité du code avec |>

```
leave_house(get_dressed(get_out_of_bed(wake_up(me, time = "8:00"),
side = "correct"), pants = TRUE, shirt = TRUE), car = TRUE, bike =
FALSE)
```

```
me |>
  wake_up(time = "8:00") |>
  get_out_of_bed(side = "correct") |>
  get_dressed(pants = TRUE, shirt = TRUE) |>
  leave_house(car = TRUE, bike = FALSE)
```

summarize()

Créer un tableau résumé

```
gapminder |> summarize(mean_life = mean(lifeExp))
```

country	continent	year	lifeExp
Afghanistan	Asia	1952	28.801
Afghanistan	Asia	1957	30.332
Afghanistan	Asia	1962	31.997
Afghanistan	Asia	1967	34.02
…	…	…	…

mean_life
59.47444

summarize()

```
gapminder |> summarize(mean_life = mean(lifeExp),
                       min_life = min(lifeExp))
```

country	continent	year	lifeExp
Afghanistan	Asia	1952	28.801
Afghanistan	Asia	1957	30.332
Afghanistan	Asia	1962	31.997
Afghanistan	Asia	1967	34.02
Afghanistan	Asia	1972	36.088
...	...	...	...

mean_life	min_life
59.47444	23.599

À votre tour #4: résumer

Utilisez `summarize()` pour calculer...

1. La première année des mesures (minimum)
2. La dernière année des mesures (maximum)
3. Le nombre de lignes dans la base de données (utilisez l'aide mémoire)
4. Le nombre de pays distincts dans la base de données (utilisez l'aide mémoire)

04:00

```
gapminder |>
  summarize(first = min(year),
            last = max(year),
            num_rows = n(),
            num_unique = n_distinct(country))
```

first	last	num_rows	num_unique
1952	2007	1704	142

À votre tour #5: résumer

Utilisez `filter()` et `summarize()` pour calculer

1. le nombre de pays
2. l'espérance de vie médiane

pour le continent africain en 2007.

04:00

```
gapminder |>
  filter(continent == "Africa", year == 2007) |>
  summarise(n_countries = n_distinct(country),
            med_le = median(lifeExp))
```

n_countries	med_le
52	52.9265

group_by()

Assembler les lignes en groupes selon les valeurs d'une colonne

```
gapminder |> group_by(continent)
```

Rien n'apparaît!

Outil puissant si combiné avec `summarize()`

```
gapminder |>
  group_by(continent) |>
  summarize(n_countries = n_distinct(country))
```

continent	n_countries
Africa	52
Americas	25
Asia	33
Europe	30
Oceania	2

```
pollution |>
  summarize(mean = mean(amount), sum = sum(amount), n = n())
```

city	particle_size	amount
New York	Large	23
New York	Small	14
London	Large	22
London	Small	16
Beijing	Large	121
Beijing	Small	56

mean	sum	n
42	252	6

```
pollution |>
  group_by(city) |>
  summarize(mean = mean(amount), sum = sum(amount), n = n())
```

city	particle_size	amount
New York	Large	23
New York	Small	14
London	Large	22
London	Small	16
Beijing	Large	121
Beijing	Small	56

city	mean	sum	n
Beijing	88.5	177	2
London	19.0	38	2
New York	18.5	37	2

```
pollution |>
  group_by(particle_size) |>
  summarize(mean = mean(amount), sum = sum(amount), n = n())
```

city	particle_size	amount
New York	Large	23
New York	Small	14
London	Large	22
London	Small	16
Beijing	Large	121
Beijing	Small	56

particle_size	mean	sum	n
Large	55.33333	166	3
Small	28.66667	86	3

À votre tour #6: grouper et résumer

Trouvez l'espérance de vie minimum, maximum et médiane par continent

Trouvez l'espérance de vie minimum, maximum et médiane par continent pour 2007 uniquement

05:00

```
gapminder |>
  group_by(continent) |>
  summarize(min_le = min(lifeExp),
            max_le = max(lifeExp),
            med_le = median(lifeExp))
```

```
gapminder |>
  filter(year == 2007) |>
  group_by(continent) |>
  summarize(min_le = min(lifeExp),
            max_le = max(lifeExp),
            med_le = median(lifeExp))
```

`dplyr`: verbes pour manipuler des données

Extraire des lignes avec `filter()`

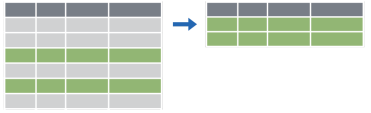

Extraire des colonnes avec `select()`

Arranger/trier les lignes avec `arrange()`

Créer/modifier des colonnes avec `mutate()`

Résumer des sous-ensembles avec `group_by() |> summarize()`