R. Работа с таблицами

Tidyverse

Tidyverse

Packages Articles Learn Help Contribute

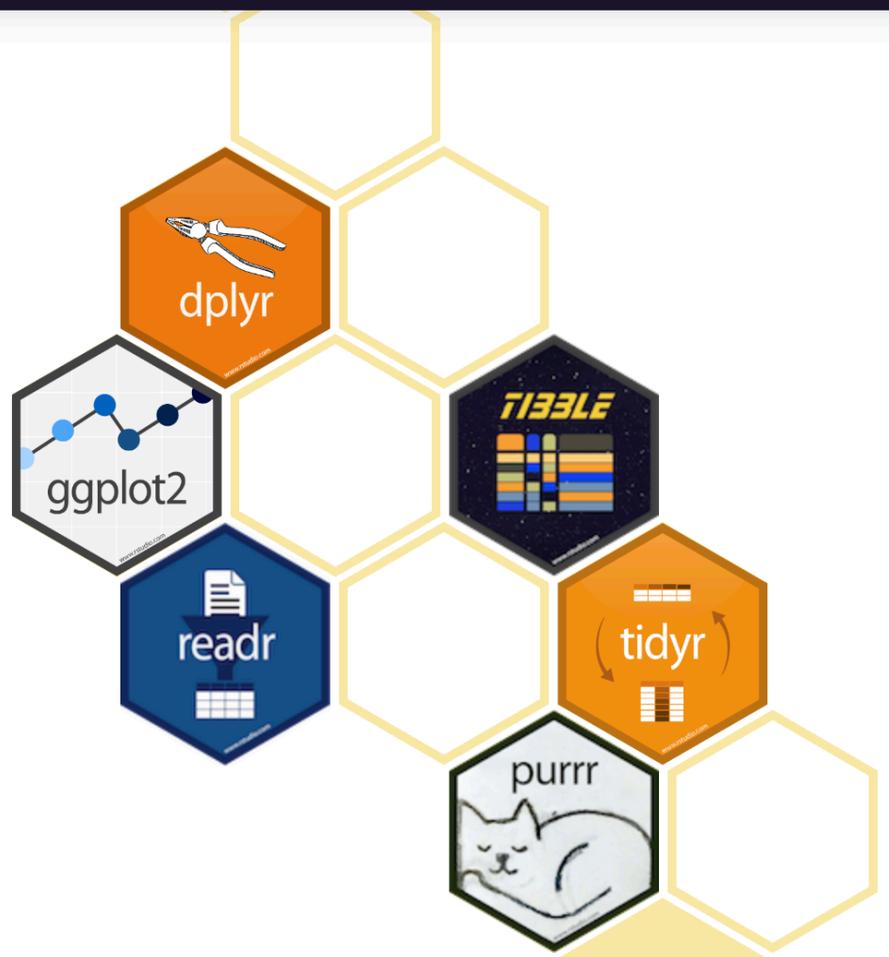

R packages for data science

The tidyverse is an opinionated collection of R packages designed for data science. All packages share an underlying design philosophy, grammar, and data structures.

Install the complete tidyverse with:

```
install.packages("tidyverse")
```

Плюсы

- Сравнительно легко освоить
- Очень удобен в использовании
- Общий синтаксис для всех пакетов
- Хорошо взаимодействует с ggplot (не входи в tidyverse) - пакетом для визуализации графики

Минусы

- Не весь R
- Синтаксис иногда меняется, в этом случае ломается все..
- Куча слоев абстракции - конкретная задача решается не напрямую, а с использованием кучи промежуточных шагов
- Как результат - можно получить абсолютно непонятный код, еще и работающий медленно

dplyr

Манипуляция данными в виде таблицы

Краткая инструкция по командам dplyr

https://github.com/rstudio/cheatsheets/blob/master/data-transformation.pdf

Установка:

```
install.packages("dplyr")
library(dplyr)
```

Примеры команд

select - выбрать какие-то колонки по имени

```
head(select(mtcars, mpg, cyl, disp))
```

```
##                   mpg cyl disp
## Mazda RX4         21.0   6  160
## Mazda RX4 Wag     21.0   6  160
## Datsun 710        22.8   4  108
## Hornet 4 Drive    21.4   6  258
## Hornet Sportabout 18.7   8  360
## Valiant           18.1   6  225
```

Имена колонок

Имя таблицы

Примеры команд

select - выбрать какие-то колонки по имени

```
head(select(mtcars, c("mpg", "cyl", "disp")))
```

```
##                   mpg cyl disp
## Mazda RX4         21.0   6  160
## Mazda RX4 Wag     21.0   6  160
## Datsun 710        22.8   4  108
## Hornet 4 Drive    21.4   6  258
## Hornet Sportabout 18.7   8  360
## Valiant           18.1   6  225
```

Имена колонок

Имя таблицы

Примеры команд

select - выбрать какие-то колонки по имени
можно использовать условия для выбора колонок,
например - starts_with позволит выбрать колонки,
начинающиеся с определенного шаблона

```
selected <- select(iris, starts_with("Sepal"))
head(selected)
```

```
##   Sepal.Length Sepal.Width
## 1          5.1         3.5
## 2          4.9         3.0
## 3          4.7         3.2
## 4          4.6         3.1
## 5          5.0         3.6
## 6          5.4         3.9
```

Условие на колонки

Имя таблицы

Примеры команд

select - выбрать какие-то колонки по имени можно использовать условия для выбора колонок, например - starts_with позволит выбрать колонки, начинающиеся с определенного шаблона. Можно комбинировать

```
selected <- select(iris, Species, starts_with("Sepal"))
head(selected)
```

```
##    Species Sepal.Length Sepal.Width
## 1   setosa          5.1         3.5
## 2   setosa          4.9         3.0
## 3   setosa          4.7         3.2
## 4   setosa          4.6         3.1
## 5   setosa          5.0         3.6
## 6   setosa          5.4         3.9
```

Условие на колонки

Имя колонки

Имя таблицы

Примеры команд

pull- выбрать одну конкретную колонку и взять ее как вектор

```
selected <- pull(iris, Sepal.Length)
print(selected)
```

```
##   [1] 5.1 4.9 4.7 4.6 5.0 5.4 4.6 5.0 4.4 4.9 5.4 4.8 4.8
##  [18] 5.1 5.7 5.1 5.4 5.1 4.6 5.1 4.8 5.0 5.0 5.2 5.2 4.7
##  [35] 4.9 5.0 5.5 4.9 4.4 5.1 5.0 4.5 4.4 5.0 5.1 4.8 5.1
##  [52] 6.4 6.9 5.5 6.5 5.7 6.3 4.9 6.6 5.2 5.0 5.9 6.0 6.1
##  [69] 6.2 5.6 5.9 6.1 6.3 6.1 6.4 6.6 6.8 6.7 6.0 5.7 5.5
##  [86] 6.0 6.7 6.3 5.6 5.5 5.5 6.1 5.8 5.0 5.6 5.7 5.7 6.2
## [103] 7.1 6.3 6.5 7.6 4.9 7.3 6.7 7.2 6.5 6.4 6.8 5.7 5.8
## [120] 6.0 6.9 5.6 7.7 6.3 6.7 7.2 6.2 6.1 6.4 7.2 7.4 7.9
## [137] 6.3 6.4 6.0 6.9 6.7 6.9 5.8 6.8 6.7 6.7 6.3 6.5 6.2
```

Имя таблицы

Имя колонки

Примеры команд

filter - отфильтровать строки по условию

```
filtered <- filter(iris, Sepal.Length > 5)
head(filtered)
```

```
##   Sepal.Length Sepal.Width Petal.Length Petal.Wi
## 1          5.1         3.5          1.4
## 2          5.4         3.9          1.7
## 3          5.4         3.7          1.5
## 4          5.8         4.0          1.2
## 5          5.7         4.4          1.5
## 6          5.4         3.9          1.3
```

Имя таблицы

Условие

Примеры команд

slice - выбрать строки по позиции

```
sliced <- slice(iris, 1:10)
head(sliced)
```

```
##   Sepal.Length Sepal.Width Petal.Length Petal.Width Specie
## 1          5.1         3.5          1.4         0.2  setos
## 2          4.9         3.0          1.4         0.2  setos
## 3          4.7         3.2          1.3         0.2  setos
## 4          4.6         3.1          1.5         0.2  setos
## 5          5.0         3.6          1.4         0.2  setos
```

Имя таблицы

Позиции

Примеры команд

slice - выбрать строки по позиции

```
sliced <- slice(iris, (n()-10):n())
head(sliced)
```

Позиции, n()-число записей

Имя таблицы

```
##    Sepal.Length Sepal.Width Petal.Length Petal.Width   Species
## 1           6.9         3.1          5.4         2.1 virginica
## 2           6.7         3.1          5.6         2.4 virginica
## 3           6.9         3.1          5.1         2.3 virginica
## 4           5.8         2.7          5.1         1.9 virginica
## 5           6.8         3.2          5.9         2.3 virginica
```

Примеры команд

sample_n - выбрать строки по позиции

```
sampled <- sample_n(iris, 10)
head(sampled)
```

Имя таблицы

```
##     Sepal.Length Sepal.Width Petal.Length Petal.
## 1            5.7         4.4          1.5
## 2            7.4         2.8          6.1
## 3            4.4         3.2          1.3
## 4            6.3         3.4          5.6
## 5            7.7         2.6          6.9
## 6            5.1         3.5          1.4
```

число сэмплируемых объектов

Примеры команд

arrange - отсортировать строки по колонкам

```
sorted <- arrange(iris, Sepal.Length)
head(sorted)
```

```
##   Sepal.Length Sepal.Width Petal.Length Pet
## 1          4.3         3.0          1.1
## 2          4.4         2.9          1.4
## 3          4.4         3.0          1.3
## 4          4.4         3.2          1.3
## 5          4.5         2.3          1.3
## 6          4.6         3.1          1.5
```

Имя таблицы

колонка, по которой сортируем

Примеры команд

arrange - отсортировать строки по колонкам

```
sorted <- arrange(iris, desc(Sepal.Length))
head(sorted)
```

колонка, по которой сортируем в порядке убывания

Имя таблицы

```
##    Sepal.Length Sepal.Width Petal.Length Petal.Wid
## 1           7.9         3.8          6.4         2
## 2           7.7         3.8          6.7         2
## 3           7.7         2.6          6.9         2
## 4           7.7         2.8          6.7         2
## 5           7.7         3.0          6.1         2
## 6           7.6         3.0          6.6         2
```

Примеры команд

arrange - отсортировать строки по колонкам

```
sorted <- arrange(iris, Sepal.Length, desc(Sepal.Width))
head(sorted)
```

```
##   Sepal.Length Sepal.Width Petal.Length Petal.Width
## 1          4.3         3.0          1.1         0.1
## 2          4.4         3.2          1.3         0.2
## 3          4.4         3.0          1.3         0.2
## 4          4.4         2.9          1.4         0.2
## 5          4.5         2.3          1.3         0.3
## 6          4.6         3.6          1.0         0.2
```

Имя таблицы

колонки, по которой сортируем, сначала по первой, потом по второй

Примеры команд

add_row -добавить строку в таблицу

```
added <- add_row(iris,
                 Sepal.Length=1,
                 Sepal.Width=2,
                 Petal.Length=3,
                 Petal.Width=0.2,
                 Species='mine',
                 .before=T)
head(added)
```

Имя таблицы

Значения колонок

Вставлять в начало

```
##   Sepal.Length Sepal.Width Petal.Length Petal.Width Species
## 1          1.0         2.0          3.0         0.2    mine
## 2          5.1         3.5          1.4         0.2  setosa
## 3          4.9         3.0          1.4         0.2  setosa
## 4          4.7         3.2          1.3         0.2  setosa
## 5          4.6         3.1          1.5         0.2  setosa
## 6          5.0         3.6          1.4         0.2  setosa
```

Примеры команд

add_column -добавить столбец в таблицу (функция из пакета tibble)

```
added <- add_column(iris, mine=1:nrow(iris))
head(added)
```

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

Значения Строк

Имя таблицы

Имя новой колонки

Примеры команд

summarise - подсчитать какое-то значение по всей колонке

```
summarise(iris, mean_sepal_length=mean(Sepal.Length) )
```

```
##   mean_sepal_length
## 1          5.843333
```

Имя таблицы

Имя новой колонки

Примеры команд

summarise - подсчитать какое-то значение по всей колонке

Имя новой колонки

```
summarise(iris,
          mean_sepal_length=mean(Sepal.Length),
          sd_sepal_length=sd(Sepal.Length))
```

```
##   mean_sepal_length sd_sepal_length
## 1          5.843333       0.8280661
```

Имя таблицы

Примеры команд

summarise - подсчитать какое-то значение по всей колонке

Имя новой колонки

```
summarise(iris,
          mean_sepal_length=quantile(Sepal.Length, 0.55))
```

```
##   mean_sepal_length
## 1               5.9
```

Имя таблицы

Примеры команд

count - подсчитать число строк, в которых значение переменной равно тому-то

```
count(iris, Sepal.Length)
```

Имя колонки

Имя таблицы

```
## # A tibble: 35 x 2
##    Sepal.Length     n
##           <dbl> <int>
##  1          4.3     1
##  2          4.4     3
##  3          4.5     1
##  4          4.6     4
##  5          4.7     2
```

Примеры команд

count - подсчитать число строк, в которых значение переменной равно тому-то

```
count(iris, Sepal.Length, Sepal.Width)
```

```
## # A tibble: 117 x 3
##    Sepal.Length Sepal.Width     n
##           <dbl>       <dbl> <int>
##  1          4.3         3       1
##  2          4.4         2.9     1
##  3          4.4         3       1
##  4          4.4         3.2     1
##  5          4.5         2.3     1
##  6          4.6         3.1     1
##  7          4.6         3.2     1
##  8          4.6         3.4     1
##  9          4.6         3.6     1
## 10          4.7         3.2     2
```

Имя колонки

Имя таблицы

Примеры команд

mutate - подсчитать новую колонку

```
mutated <- mutate(iris, inv_length=1/Sepal.Length)
head(mutated)
```

```
##   Sepal.Length Sepal.Width Petal.Length Petal.Width Specie
## 1          5.1         3.5          1.4         0.2  setos
## 2          4.9         3.0          1.4         0.2  setos
## 3          4.7         3.2          1.3         0.2  setos
## 4          4.6         3.1          1.5         0.2  setos
## 5          5.0         3.6          1.4         0.2  setos
## 6          5.4         3.9          1.7         0.4  setos
```

Имя таблицы

Имя колонки

Примеры команд

mutate - подсчитать новую колонку

```
mutated <- mutate(iris,
                  inv_length=1/Sepal.Length,
                   inv_width=1/Sepal.Width)

head(mutated)
```

```
##   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
##    inv_width
## 1 0.2857143
## 2 0.3333333
```

Имя таблицы

Имя колонки

Примеры команд

transmute - подсчитать новую колонку, убрать остальные

```
transmuted <- transmute(iris, inv_length=1/Sepal.Length)
head(transmuted)
```

```
##    inv_length
## 1   0.1960784
## 2   0.2040816
## 3   0.2127660
## 4   0.2173913
## 5   0.2000000
## 6   0.1851852
```

Имя колонки

Имя таблицы

Примеры команд

transmute - подсчитать новую колонку, убрать остальные

```
transmuted <- transmute(iris,
                        inv_length=1/Sepal.Length,
                        inv_width=1/Sepal.Width)

head(transmuted)
```

Имя колонки

```
##    inv_length inv_width
## 1   0.1960784 0.2857143
## 2   0.2040816 0.3333333
## 3   0.2127660 0.3125000
## 4   0.2173913 0.3225806
## 5   0.2000000 0.2777778
## 6   0.1851852 0.2564103
```

Имя таблицы

Примеры команд

rename - переименовать колонку

```
renamed <- rename(iris,
                  Length=Sepal.Length)

head(renamed)
```

Новое имя колонки

Старое имя колонки

Имя таблицы

```
##    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
```

Pipe %>%

Имя таблицы

Позволяет направить таблицу, полученную одной командой, в другую команду в качестве первого аргумента

```
starwars %>%
  mutate(bmi = mass / ((height / 100)  ^ 2)) %>%
  select(name:mass, bmi)
```

Добавляем индекс массы тела

Выбираем колонки от name до mass

```
## # A tibble: 87 x 4
##    name               height  mass   bmi
##    <chr>               <int> <dbl> <dbl>
##  1 Luke Skywalker        172    77  26.0
##  2 C-3PO                 167    75  26.9
##  3 R2-D2                  96    32  34.7
```

group_by

```
starwars %>%
  group_by(species) %>%
    count()
```

```
## # A tibble: 38 x 2
## # Groups:   species [38]
##    species        n
##    <chr>      <int>
##  1 <NA>           5
##  2 Aleena         1
##  3 Besalisk       1
```

Позволяет сгруппировать таблицу (фактически - разбить ее на под-таблицы) по колонке/группе колонок

group_by

```
starwars %>%
  group_by(species) %>%
    summarise(num=n()) %>% arrange(desc(num))
```

```
## # A tibble: 38 x 2
##      species     num
##        <chr>   <int>
##  1   Human        35
##  2    <NA>         5
##  3   Droid         5
##  4  Gungan         3
##  5 Kaminoan        2
```

Позволяет сгруппировать таблицу (фактически - разбить ее на под-таблицы) по колонке/группе колонок и затем трансформировать получившиеся подтаблицы

Pipe %>%

```
starwars %>%
  group_by(species) %>%
  summarise(
    n = n(),
    mass = mean(mass, na.rm = TRUE)
  ) %>%
  filter(n > 1,
         mass > 50)
```

Группируем по species

Посчитаем, сколько какого вида и среднюю массу

Отберем случаи, когда представителей виде было больше 1 и средняя масса вида больше 50

```
## # A tibble: 8 x 3
##   species       n  mass
##   <chr>     <int> <dbl>
## 1 Droid         5  69.8
## 2 Gungan        3  74
```

Можно присваивать

```
species_mass_filtered <- starwars %>%
  group_by(species) %>%
  summarise(
    n = n(),
    mass = mean(mass, na.rm = TRUE)
  ) %>%
  filter(n > 1,
         mass > 50)
```

Аналог dplyr

data.tables

Функционал схожий
Работает в разы быстрее

Синтаксис на первый взгляд менее понятен

```
DT[i, j, by]

##   R:                 i                 j        by
## SQL:  where | order by   select | update  group by
```

data.tables

Синтаксис на первый взгляд менее понятен

Да и на второй.

Повторение задачи с starwars

```
starwars <- as.data.table(starwars)
starwars[, .(num=.N, mass=mean(mass, na.rm=T)), species][num > 1 & mass > 50, ]
```

```
##      species num      mass
## 1:     Human  35  82.78182
## 2:     Droid   5  69.75000
## 3:   Wookiee   2 124.00000
## 4:    Gungan   3  74.00000
## 5:    Zabrak   2  80.00000
## 6:   Twi'lek   2  55.00000
## 7: Mirialan   2  53.10000
## 8: Kaminoan   2  88.00000
```

Зато он быстрее

data.tables

- Функция fread из этого пакета - очень быстрое чтение таблиц. Можно использовать только ее.