

Zaawansowane typy danych.ipynb

Statystyka I z R

Bartosz Maćkiewicz

Zaawansowane typy danych

W tej części kursu będziemy omawiać bardziej zaawansowane typy danych, z którymi możemy pracować w R.

Dygresja: dolna_granica:górna_granica

Na początek nauczymy się tworzenia wektorów liczb całkowitych (`integer`) za pomocą konstrukcji `dolna_granica:górna_granica`.

Jest to bardzo często wykorzystywany sposób, który pojawiać będzie się przez cały kurs.

```
dwadziescia_liczb <- 1:20 # Tworzymy wektor typu integer z liczbami od 1 do 20
dwadziescia_liczb # sprawdzamy czy rzeczywiście się utworzył
```

```
## [1] 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20
```

```
class(dwadziescia_liczb) # sprawdzamy jego typ
```

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

Jeżeli jako pierwszą podamy mniejszą liczbę, to R z takim wypadkiem sobie poradzi i również utworzy ciąg liczb całkowitych.

```
5:1
```

```
## [1] 5 4 3 2 1
```

Jeżeli interesują nas bardziej wyrafinowane sekwencje liczb, to powinniśmy zainteresować się funkcją `seq`. Poniżej znajduje się przykład polecenia, tworzącego sekwencję liczb całkowitych od 5 do 56, w której każda kolejna liczba jest większa od poprzedniej o 3. Więcej o tej funkcji można znaleźć w dokumentacji (`?seq`)

```
seq(from = 5, to = 55, by = 3)
```

```
## [1] 5 8 11 14 17 20 23 26 29 32 35 38 41 44 47 50 53
```

Macierze

Utwórzmy też macierz o wymiarach 4x5. Kolejne liczby z wektora `dwadziescia_liczb` wypełniają po kolei kolumny naszej macierzy. Zrobimy to za pomocą funkcji `matrix`.

```
matrix(dane, wiersze, kolumny)
```

- `dane` - wartości, którymi chcemy wypełnić macierz
- `wiersze` - liczba wierszy
- `kolumny` - liczba kolumn

Warto w tym miejscu zwrócić uwagę na dwa fakty.

1. R domyślnie wypełnia macierze kolumnami

2. Jeżeli jakaś funkcja przyjmuje jako argumenty wymiary jakiejś dwuwymiarowej struktury danych, to najpierw podaje się liczbę wierszy a dopiero potem liczbę kolumn. Oto mnemotechniczna rymowanka, która pozwala zapamiętać to zachowanie: *wiersze pierwsze*.

```
macierz <- matrix(dwadziescia_liczb, 4,5)
macierz
```

```
##      [,1] [,2] [,3] [,4] [,5]
## [1,]    1    5    9   13   17
## [2,]    2    6   10   14   18
## [3,]    3    7   11   15   19
## [4,]    4    8   12   16   20
```

Za pomocą argumentu `byrow` możemy jednak wypełniać macierz wierszami.

```
macierz_wiersze <- matrix(dwadziescia_liczb, 4,5, byrow = TRUE)
macierz_wiersze
```

```
##      [,1] [,2] [,3] [,4] [,5]
## [1,]    1    2    3    4    5
## [2,]    6    7    8    9   10
## [3,]   11   12   13   14   15
## [4,]   16   17   18   19   20
```

Do macierzy możemy dodawać nowe wiersze i kolumny za pomocą funkcji `cbind` i `rbind`.

```
print(cbind(macierz_wiersze, c(1000,2000,3000,400))) # analogicznie rbind
```

```
##      [,1] [,2] [,3] [,4] [,5] [,6]
## [1,]    1    2    3    4    5 1000
## [2,]    6    7    8    9   10 2000
## [3,]   11   12   13   14   15 3000
## [4,]   16   17   18   19   20  400
```

```
print(rbind(macierz_wiersze, macierz_wiersze)) # możemy nawet "złączyć" dwie macierze w ten sam sposób
```

```
##      [,1] [,2] [,3] [,4] [,5]
## [1,]    1    2    3    4    5
## [2,]    6    7    8    9   10
## [3,]   11   12   13   14   15
## [4,]   16   17   18   19   20
## [5,]    1    2    3    4    5
## [6,]    6    7    8    9   10
## [7,]   11   12   13   14   15
## [8,]   16   17   18   19   20
```

Na macierzach podobnie jak na wektorach możemy wykonywać operacje element-po-element, na przykład mnożenie.

```
macierz * macierz_wiersze # mnożenie R-owe, "element-po-element"
```

```
##      [,1] [,2] [,3] [,4] [,5]
## [1,]    1   10   27   52   85
## [2,]   12   42   80  126  180
## [3,]   33   84  143  210  285
## [4,]   64  136  216  304  400
```

Możemy również wykonywać operacje algebraiczne na macierzach.

```
a <- matrix(c(2,4,6,8,10,12,14,18), 2,4)
a
```

```
##      [,1] [,2] [,3] [,4]
## [1,]    2    6   10   14
## [2,]    4    8   12   18
```

```
b <- matrix(c(9,8,7,6,5,4,3,2), 4,2)
b
```

```
##      [,1] [,2]
## [1,]    9    5
## [2,]    8    4
## [3,]    7    3
## [4,]    6    2
```

```
a %*% b # iloczyn macierzy
```

```
##      [,1] [,2]
## [1,]   220   92
## [2,]   292  124
```

Inne przydatne podstawowe operacje:

- t - transpozycja

```
# inny sposób tworzenia macierzy za pomocą funkcji cbind (*column bind*)
macierz_2 <- cbind(30:40, 25:35, 130:140)
t(macierz_2) # Transpozycja
```

```
##      [,1] [,2] [,3] [,4] [,5] [,6] [,7] [,8] [,9] [,10] [,11]
## [1,]   30   31   32   33   34   35   36   37   38   39   40
## [2,]   25   26   27   28   29   30   31   32   33   34   35
## [3,]  130  131  132  133  134  135  136  137  138  139  140
```

- rowSums, colSums, rowMeans, colMeans - sumy/średnie kolumnami/wierszami

```
rowMeans(macierz_2) # analogiczne colMeans
```

```
## [1] 61.66667 62.66667 63.66667 64.66667 65.66667 66.66667 67.66667 68.66667
## [9] 69.66667 70.66667 71.66667
```

```
colSums(macierz_2) # analogicznie rowSums
```

```
## [1]  385  330 1485
```

O wymiarach macierzy możemy się dowiedzieć za pomocą funkcji dim, ncol, nrow

```
dim(macierz_2) # wymiary
```

```
## [1] 11  3
```

```
ncol(macierz_2) # liczba kolumn
```

```
## [1] 3
```

```
nrow(macierz_2) # liczba wierszy
```

```
## [1] 11
```

Dla naszych celów ta wiedza powinna wystarczyć, statystycy z socjologii prosili jednak o podstawy algebry w R. Polecam więc zajrzenie w stosownym czasie do np. Algebra w R (polecam również samą stronę!)

Listy

Listy w przeciwieństwie do wektorów przechowują sekwencje wartości różnych typów. Możemy w niej przechowywać wektory różnych typów o różnej długości a nawet inne listy. W tym sensie są podobne do list z niektórych innych języków programowania. Listy tworzymy za pomocą funkcji `list`.

```
lista <- list(c(1,2,3,4,5), # pierwszy element: wektor typu `integer`
             c('Adam', 'Marysia', 'Zosia', 'Tosia'), # drugi element: wektor typu `character`
             TRUE, # trzeci element: wektor typu `logical`
             TRUE, # czwarty element: wektor typu `logical`
             list( # piąty element: lista
                   c(-1,-2,-3) # pierwszy element: wektor typu `numeric`
                 )
            )

lista

## [[1]]
## [1] 1 2 3 4 5
##
## [[2]]
## [1] "Adam"      "Marysia" "Zosia"   "Tosia"
##
## [[3]]
## [1] TRUE
##
## [[4]]
## [1] TRUE
##
## [[5]]
## [[5]][[1]]
## [1] -1 -2 -3
```

Elementom listy możemy nadawać nazwy. Dlatego w niektórych sytuacjach możemy traktować je jak słowniki z innych języków programowania, przechowujące pary klucz-wartość.

Nazwane listy również tworzymy przy pomocy funkcji `list`.

```
lista_nazwana <- list(liczby_od_jeden_do_piec = c(1,2,3,4,5),
                     imiona = c('Adam', 'Marysia', 'Zosia', 'Tosia'),
                     czy_r_jest_fajny = TRUE,
                     czy_zajecia_sa_fajne = TRUE,
                     lista_zagniezdzona = list(c(-1,-2,-3)))

lista_nazwana

## $liczby_od_jeden_do_piec
## [1] 1 2 3 4 5
##
## $imiona
## [1] "Adam"      "Marysia" "Zosia"   "Tosia"
##
## $czy_r_jest_fajny
## [1] TRUE
##
## $czy_zajecia_sa_fajne
## [1] TRUE
##
## $lista_zagniezdzona
```

```
## $lista_zagniezdzona[[1]]  
## [1] -1 -2 -3
```

Do list wrócimy jeszcze kiedy będziemy mówić o indeksowaniu.

Ramki danych (*data frame*)

Ramki danych (*data frame*) są typem danych, z którym w praktyce będziemy pracować najczęściej. O ramkach danych można myśleć jako np. o tabelach Excela, w której każdy wiersz reprezentuje jedną obserwację.

Tworzenie ramek danych jest dość podobne do tworzenia list. To, co w listach było nazwami elementów, w przypadku ramek danych będzie nazwami kolumn. Poniżej znajduje się kilka przydatnych sposobów tworzenia ramek danych. Na razie pomijamy najczęściej wykorzystywany w praktyce sposób. Z reguły bowiem ramki danych będziemy tworzyć wczytując dane z pliku. Tym jednak zajmiemy się później.

Podstawowy sposób stworzenia ramki danych wygląda tak:

```
x <- c('Kasia', 'Zosia', 'Marysia', 'Tosia', 'Zbyszek')  
y <- factor(c('F', 'F', 'F', 'F', 'M'), levels = c('F', 'M'))  
z <- c(2, 4, 5, 8, 2)  
  
# ramki danych tworzy się w zasadzie tak samo jak listy  
dane <- data.frame(imie = x,  
                   plec = y,  
                   liczba_jabluszek = z  
                   )  
dane
```

```
##      imie plec liczba_jabluszek  
## 1   Kasia   F                2  
## 2   Zosia   F                4  
## 3 Marysia   F                5  
## 4   Tosia   F                8  
## 5 Zbyszek   M                2
```

Jeśli mamy listę, której elementy są wektorami równej długości, to możemy przekonwertować ją na ramkę danych.

```
lista_nie_ramka <- list(imie = x,  
                        plec = y,  
                        liczba_jabluszek = z)  
data.frame(lista_nie_ramka)
```

```
##      imie plec liczba_jabluszek  
## 1   Kasia   F                2  
## 2   Zosia   F                4  
## 3 Marysia   F                5  
## 4   Tosia   F                8  
## 5 Zbyszek   M                2
```

W ramce danych nie tylko kolumny mogą mieć swoją nazwę. Możemy ustalić, że również każdy wiersz będzie miał nazwę. Uczynimy to przekazując funkcji `data.frame` argument `row.names` w postaci wektora z nazwami.

```
data.frame(plec = y,  
           liczba_jabluszek = z,  
           row.names = x)
```

```
##      plec liczba_jabluszek
```

```
## Kasia      F      2
## Zosia      F      4
## Marysia    F      5
## Tosia      F      8
## Zbyszek    M      2
```

Do postaci ramki danych możemy przekonwertować również macierz. Czasami jest to przydatne. Służy do tego funkcja `as.data.frame`.

```
ramka_z_macierzy <- as.data.frame(macierz) # możemy utworzyć z macierzy
ramka_z_macierzy
```

```
##   V1 V2 V3 V4 V5
## 1  1  5  9 13 17
## 2  2  6 10 14 18
## 3  3  7 11 15 19
## 4  4  8 12 16 20
```

Powiedzieliśmy sobie, że w ramkach danych kolumny oraz wiersze mogą mieć nazwy. Jeśli chodzi o kolumny, to funkcji `colnames` zwraca wektor z nazwami kolumn ramki danych.

```
dane
```

```
##      imie  plec liczba_jabluszek
## 1   Kasia    F      2
## 2   Zosia    F      4
## 3 Marysia    F      5
## 4   Tosia    F      8
## 5 Zbyszek    M      2
```

```
colnames(dane)
```

```
## [1] "imie"          "plec"          "liczba_jabluszek"
```

Za pomocą tej samej funkcji możemy zmienić też nazwy. Wystarczy, że nadpiszemy zwrócony przez funkcję `colnames` wektor swoim własnym wektorem, w którym zawrzemy nowe nazwy kolumn. To samo możemy zrobić również z nazwami wierszy, korzystając w funkcji `rownames`.

```
ramka_z_macierzy
```

```
##   V1 V2 V3 V4 V5
## 1  1  5  9 13 17
## 2  2  6 10 14 18
## 3  3  7 11 15 19
## 4  4  8 12 16 20
```

```
# Zastępujemy domyślnie nazwy kolumn (V1, V2, V3...) swoimi własnymi.
colnames(ramka_z_macierzy) <- c('Jeden', 'Dwa', 'Trzy', 'Cztery', 'Pięć')
ramka_z_macierzy
```

```
##   Jeden Dwa Trzy Cztery Pięć
## 1     1  5  9    13    17
## 2     2  6 10    14    18
## 3     3  7 11    15    19
## 4     4  8 12    16    20
```