ITAP - Osnove uporabe R

A. Blejec

andrej.blejec@nib.si

Nacionalni inštitut za biologijo
in
Univerza v Ljubljani
BF Oddelek za biologijo

February 8, 2009

Povezave

Domača stran R projekta

http://www.r-project.org

Bližnji repozitorij **CRAN** (Dunaj)

http://cran.at.r-project.org/

Najnovejša verzija R na **CRAN** (Dunaj)

http://cran.at.r-project.org/bin/windows/base/release.htm

Tinn-R GUI/Editor

http://www.sciviews.org/Tinn-R/

WinEdt - ASCII urejevalnik (shareware)

http://www.winedt.com/

Materiali o R na moji spletni strani

http://ablejec.nib.si/R in http://ablejec.nib.si/ITAP

Moj e-mail naslov

andrej.blejec@nib.si

Elementarna aritmetika

Operatorji: + − / * ^

```
> 2+3 # izračuna 2+3, vse za znakom # je komentar
[1] 5
> 2*3 # aritmetika v R: + - * /
[1] 6
> 2^3 # in potenca
[1] 8
> sqrt(4) # funkcije imajo v oklepajih argumente
[1] 2
> # sqrt(-4)     # kar tako ne bo šlo :
> sqrt(as.complex(-4))     # R pozna kompleksna števila
[1] 0+2i
> sqrt(-4+0i) # isto kot zgoraj
[1] 0+2i
```

Zaokroževanje

```
> x <- 7/6
> round(x)
[1] 1
> round(x,3)
[1] 1.167
> floor(x)
[1] 1
> ceiling(x)
[1] 2
> format(1/2,nsmall=3)
[1] "0.500"
```

Nekaj konstant

`pi`	π
`NA`	manjkajoča vrednost
`NaN`	"not a number"
`Inf`	neskončno (`1/0`)
`NULL`	prazna vrednost
`letters`	male črke angleške abecede
`LETTERS`	velike črke angleške abecede

Funkcije vrste `is.nekaj` in `as.nekaj`

```
> is.na(111)
[1] FALSE
> is.numeric(111)
[1] TRUE
> as.character(111)
[1] "111"
> (x <- c(1,2,NA,NULL,5,"bla"))  # prisiljeni znaki!!
[1] "1"   "2"   NA    "5"   "bla"
> is.null(x)
[1] FALSE
> is.na(x)
[1] FALSE FALSE  TRUE FALSE FALSE
```

Rezultate lahko shranimo v imenovane objekte

```
> x <- 2+2
> y <- 2^3
> x
[1] 4
> y
[1] 8
> ime <- x  # v imenih razlikuje velike in male črke
> IME <- y
> ls()      # seznam objektov
[1] "ime" "IME" "x"   "y"
```

Logični vrednosti in operatorji

```
> x<y      # "logical"
[1] TRUE
> x>=20    # primerjalni operatorji: < <= > >= == !=
[1] FALSE
> x!=y     # x ni enak y
[1] TRUE
> z <- T   # logični konstanti T in F
> z
[1] TRUE
```

Priporočljivo je uporabljati polni besedi `TRUE` in `FALSE`

Tipi vrednosti: numeric, logical, character, factor, ordered

```
> is.character("Besedilo")
[1] TRUE
> is.numeric(x<y)
[1] FALSE
> as.numeric(x<y)
[1] 1
> as.character(x<y)
[1] "TRUE"
> library(chron)     # knjižnica datumskih funkcij
> apropos("date")    # ko že govorimo o datumih :)
 [1] "-.Date"                    ".__C__Date"
 [3] "[.Date"                    "[[.Date"
 [5] "[<-.Date"                  "+.Date"
 [7] "as.character.Date"         "as.data.frame.Date"
 [9] "as.Date"                   "as.Date.character"
[11] "as.Date.date"              "as.Date.dates"
```

vector

Funkcija combine `c(...)` zlepi vrednosti v vektor:

```
> c(1,2,3,10,20,4)          # posamezne vrednosti lahko zl
[1]  1  2  3 10 20  4
> x <- c(1,2,3,10,20,4)     # vektor shranim v objekt x
> x                         # izpiše objekt po vrednostih
[1]  1  2  3 10 20  4
> print(x)                  # isto kot zgoraj,
[1]  1  2  3 10 20  4
> length(x)                 # vektorji imajo dolžino
[1] 6
```

Vektorska aritmetika

R uporablja aritmetiko na komponentah vektorjev

```
> y <- c(3, 4, 5, 11, 12, 13)    # še en vektor
> x
[1]  1  2  3 10 20  4
> y
[1]  3  4  5 11 12 13
> x + y                          # vsota
[1]  4  6  8 21 32 17
> x * y                          # in produkt po komponentah
[1]   3   8  15 110 240  52
> round(sqrt(x),2)               # tudi funkcije delujejo na k
[1] 1.00 1.41 1.73 3.16 4.47 2.00
> x < y                          # pa primerjave tudi
[1]  TRUE  TRUE  TRUE  TRUE FALSE  TRUE
```

Dopolnjevanje krajših operandov

Če operanda nista enako dolga, se krajši podaljša na potrebno dolžino.

```
> x * 2                 # množenje s konstanto
[1]  2  4  6 20 40  8
> x * c(2, -2)          # če zmanjka vrednosti za račun, se p
[1]   2  -4   6 -20  40  -8
> rep(c(2, -2), 3) # v tem primeru takole
[1]  2 -2  2 -2  2 -2
```

Če daljši ni monogokratnik krajšega, se izpiše opozorilo (**warning**)

Zaporedja števil: seq

```
> args(seq.default)          # argumenti funkcije
function (from = 1, to = 1, by = ((to - from)/(length.ou
    length.out = NULL, along.with = NULL, ...)
NULL
> 1:6                        # zaporedje števil (by = 1)
[1] 1 2 3 4 5 6
> 6:1                        # padajoče (by = -1)
[1] 6 5 4 3 2 1
> seq(1, 6, 2)               # by = 2
[1] 1 3 5
> seq(6, 1, -2)              # by = -2
[1] 6 4 2
> seq(1, 6, length=3)        # znana dolžina
[1] 1.0 3.5 6.0
```

Ponavljanje vrednosti: `rep`

```
> rep(2,6)
[1] 2 2 2 2 2 2
> rep(c(1,2),times=3)
[1] 1 2 1 2 1 2
> rep(c(1,2),each=3)
[1] 1 1 1 2 2 2
> rep(c(1,2),length=6)
[1] 1 2 1 2 1 2
> expand.grid(1:2,1:3)
  Var1 Var2
1    1    1
2    2    1
3    1    2
4    2    2
5    1    3
6    2    3
```

Izbiranje komponent vektorjev

```
> (x <- c(1,2,3,1,2,4))
[1] 1 2 3 1 2 4
> x[4]          # četrti element
[1] 1
> x[3:5]        # 3., 4. in 5. element
[1] 3 1 2
> x[c(1,4,2)] # pa še malo mešamo :-)
[1] 1 1 2
> x[-1]         # prvega spustimo
[1] 2 3 1 2 4
```

Spreminjanje vrednosti izbranim komponentam vektorjev

```
> x
[1] 1 2 3 1 2 4
> x[4] <- 40                    # posameznemu elementu
> x
[1]  1  2  3 40  2  4
> x[3:5] <- c(33,44,55); x      # 3. do 5. element; izpis
[1]  1  2 33 44 55  4
> x[c(1,4,2)] <- 11             # vsem enako vrednost
> x
[1] 11 11 33 11 55  4
> x[-1] <- 22                   # vsem razen prvemu
> x
[1] 11 22 22 22 22 22
```

Logične operacije in izbira vrednosti

```
> x
[1] 11 22 22 22 22 22
> y
[1]  3  4  5 11 12 13
> x>5
[1] TRUE TRUE TRUE TRUE TRUE TRUE
> which(x>5)
[1] 1 2 3 4 5 6
> y[x>5]        # elementi y, ki ustrezajo legi x>5
[1]  3  4  5 11 12 13
> (x>3)|(y<2) # logične operacije z vektorji & (and) | (
[1] TRUE TRUE TRUE TRUE TRUE TRUE
```

Vrednosti lahko vpišemo s tipkovnico

Vnos zaključimo s tipko Enter v prazni vrstici

```
z <- scan()
11
22
33
44
55
66
  <Enter>
```

```
> (z <- c(11,22,33,44,55,66)) # priredi in izpiši
[1] 11 22 33 44 55 66
> y
[1]  3  4  5 11 12 13
> x
[1] 11 22 22 22 22 22
```

Lepljenje vektorjev

```
> cbind(x,y,z)     # vektorje lahko zlepimo v tabelo, kot
      x  y  z
[1,] 11  3 11
[2,] 22  4 22
[3,] 22  5 33
[4,] 22 11 44
[5,] 22 12 55
[6,] 22 13 66
> rbind(x,y,z)     # ali pa kot vrstice (r)
  [,1] [,2] [,3] [,4] [,5] [,6]
x   11   22   22   22   22   22
y    3    4    5   11   12   13
z   11   22   33   44   55   66
```

`matrix` in transpozicija

`t(...)` transponira matriko (zamenja indeksa vrstic in stolpcev)

```
> u <- cbind(x,y,z)
> dim(u)              # u ima dve dimenziji (6 vrstic, 3 sto

[1] 6 3

> is.matrix(u)        # zato je matrika

[1] TRUE

> t(u)

  [,1] [,2] [,3] [,4] [,5] [,6]
x   11   22   22   22   22   22
y    3    4    5   11   12   13
z   11   22   33   44   55   66
```

Preoblikovanje vektorja v matriko

```
> c(x,y,z)     # tole pa zlepi vektorje v en sam dolg vek
 [1] 11 22 22 22 22 22  3  4  5 11 12 13 11 22 33 44 55
[18] 66
> matrix(c(x,y,z),ncol=3) # ki ga lahko preoblikujemo v
     [,1] [,2] [,3]
[1,]   11    3   11
[2,]   22    4   22
[3,]   22    5   33
[4,]   22   11   44
[5,]   22   12   55
[6,]   22   13   66
```

Preoblikovanje vektorja v matriko

```
> matrix(c(x,y,z),nrow=6) # ce mu predpišem št. vrstic a
     [,1] [,2] [,3]
[1,]   11    3   11
[2,]   22    4   22
[3,]   22    5   33
[4,]   22   11   44
[5,]   22   12   55
[6,]   22   13   66
> matrix(c(x,y,z),nrow=6,byrow=T) # matriko lahko napoln
     [,1] [,2] [,3]
[1,]   11   22   22
[2,]   22   22   22
[3,]    3    4    5
[4,]   11   12   13
[5,]   11   22   33
[6,]   44   55   66
```

data.frame - podatkovni okvir

```
> data.frame(x,y,z)    # podobno cbind
```

```
   x  y  z
1 11  3 11
2 22  4 22
3 22  5 33
4 22 11 44
5 22 12 55
6 22 13 66
```

```
> cbind(x,y,z)
```

```
     x  y  z
[1,] 11  3 11
[2,] 22  4 22
[3,] 22  5 33
[4,] 22 11 44
[5,] 22 12 55
[6,] 22 13 66
```

```
> names(cbind(x,y,z)) # cbind ne naredi imen
```

```
NULL
```

Imena spremenljivk

```
> v <- data.frame(x=x,drugi=y,z=z)     # data frame pa
> dimnames(v) # imena vseh dimenzij

[[1]]
[1] "1" "2" "3" "4" "5" "6"

[[2]]
[1] "x"     "drugi" "z"

> names(v)     # imena stolpcev (navadno spremenljivk)

[1] "x"     "drugi" "z"

> dimnames(v)[[2]]

[1] "x"     "drugi" "z"
```

`read.table` prebere podatke v `data.frame`

```
> dbmi <- read.table("..\\data\\bmi.txt",header=T)
> head(dbmi)
  id spol lroj starost visina teza
1  1    Z 1941      19  165.0 48.8
2  2    Z 1941      18  155.7 48.9
3  3    Z 1941      19  153.6 55.5
4  4    Z 1941      18  163.4 69.7
5  5    Z 1941      19  164.7 60.8
6  6    Z 1941      19  163.6 58.6
```

Najbogatejša struktura: `list`

```
> w <- list("Mešane komponente",1:3,dva=x,mat=u)   # krat
> w

[[1]]
[1] "Mešane komponente"

[[2]]
[1] 1 2 3

$dva
[1] 11 22 22 22 22 22

$mat
      x  y  z
[1,] 11  3 11
[2,] 22  4 22
[3,] 22  5 33
[4,] 22 11 44
[5,] 22 12 55
[6,] 22 13 66
```

`list`: Izbiranje komponent

Komponente lahko izberem z navedbo lege `[[...]]`

```
> w[[3]]
[1] 11 22 22 22 22 22
```

ali pa imena (`$`)

```
> w$dva
[1] 11 22 22 22 22 22
```

`list`: Izbiranje komponent

Šlo bi tudi z `[...]`

Enojni oklepaji vrnejo komponento kot `list`:

```
> w[3]

$dva
[1] 11 22 22 22 22 22

> mode(w[3]);mean(w[3])

[1] "list"

[1] NA


> w[[3]]

[1] 11 22 22 22 22 22

> mode(w[[3]]);mean(w[[3]])

[1] "numeric"

[1] 20.16667
```

Izbira vzorca

```
> N <- dim(dbmi)[1]
> n <- 20
> (select <- sample(1:N,n))

 [1]  166  277 1005   49  673  417  855 1115  576 1418
[11]  225  483  115  211  578  465  863  610  947  265

> data <- dbmi[select,]
> dimnames(data)

[[1]]
 [1] "166"  "277"  "1005" "49"   "673"  "417"  "855"
 [8] "1115" "576"  "1418" "225"  "483"  "115"  "211"
[15] "578"  "465"  "863"  "610"  "947"  "265"

[[2]]
[1] "id"      "spol"    "lroj"    "starost" "visina"
[6] "teza"

> dimnames(data)[[1]] <- 1:n
```

Nova spremenljivka

```
> attach(data)
> bmi <- teza/(visina/100)^2
> data <- cbind(data,bmi)    # podatkom dodamo novo sprem
```

Vzorec

	id	spol	lroj	starost	visina	teza	bmi
1	183	Z	1941	19	157.0	55.6	22.55670
2	111	Z	1942	19	162.2	55.2	20.98154
3	137	M	1942	19	171.4	59.3	20.18520
4	49	Z	1941	20	170.1	65.4	22.60316
5	113	Z	1945	20	155.0	50.7	21.10302
6	41	Z	1944	20	166.3	61.1	22.09310
7	175	M	1941	19	181.5	66.2	20.09577
8	27	M	1943	20	169.5	73.0	25.40876
9	10	Z	1945	20	161.5	56.5	21.66224
10	20	M	1946	18	177.4	72.0	22.87838
11	55	Z	1942	19	166.3	53.2	19.23655
12	120	Z	1944	19	173.4	59.0	19.62248
13	126	Z	1941	19	149.9	60.5	26.92478
14	40	Z	1942	18	163.4	55.8	20.89922
15	12	Z	1945	19	167.0	53.8	19.29076
16	101	Z	1944	20	169.5	61.5	21.40601
17	185	M	1941	19	184.1	79.7	23.51531
18	46	Z	1945	20	152.8	46.7	20.00185
19	72	M	1942	19	169.8	63.5	22.02411
20	99	Z	1942	19	155.5	58.1	24.02787

`id` se ponavlja znotraj leta

```
> plot(dbmi[,c("id","lroj")])
```

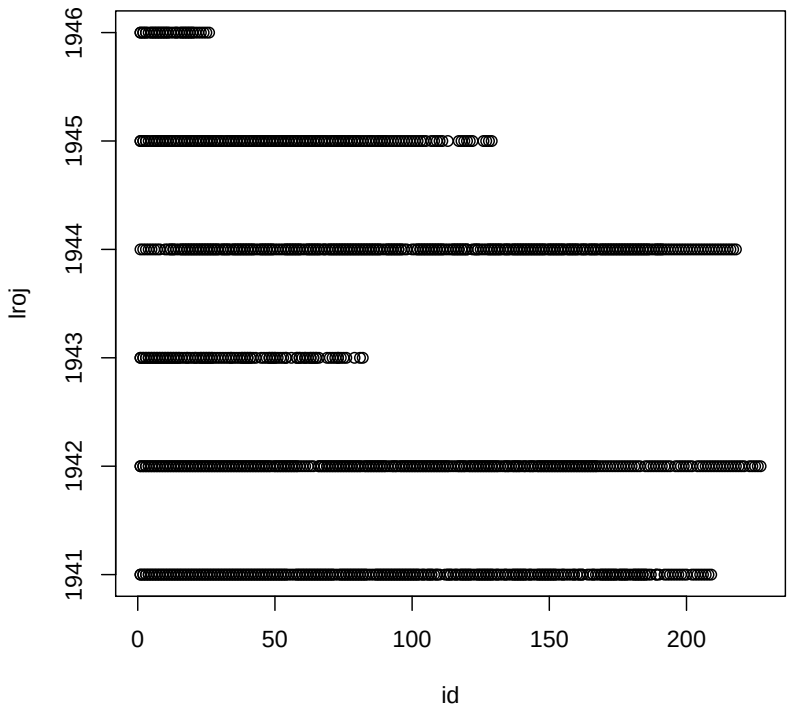

Lahki

```
> which(teza<60)

 [1]  1  2  3  5  9 11 12 14 15 18 20

> data[teza<60,]

    id spol lroj starost visina teza      bmi
1  183    Z 1941       19  157.0 55.6 22.55670
2  111    Z 1942       19  162.2 55.2 20.98154
3  137    M 1942       19  171.4 59.3 20.18520
5  113    Z 1945       20  155.0 50.7 21.10302
9   10    Z 1945       20  161.5 56.5 21.66224
11  55    Z 1942       19  166.3 53.2 19.23655
12 120    Z 1944       19  173.4 59.0 19.62248
14  40    Z 1942       18  163.4 55.8 20.89922
15  12    Z 1945       19  167.0 53.8 19.29076
18  46    Z 1945       20  152.8 46.7 20.00185
20  99    Z 1942       19  155.5 58.1 24.02787
```

Vrste vrnjenih rezultatov

- Posamezne vrednosti
- `vector`
- `matrix`
- `list`

Posamezne vrednosti

Rezultat enostavnih funkcij je posamezna vrednost

```
> x <- visina
> xBar <- mean(x)
> xBar
```

```
[1] 166.18
```

```
> str(xBar)
```

```
 num 166
```

Rezultate lahko uporabimo v analizi

```
> x-xBar
```

```
 [1]  -9.18  -3.98   5.22   3.92 -11.18   0.12  15.32
 [8]   3.32  -4.68  11.22   0.12   7.22 -16.28  -2.78
[15]   0.82   3.32  17.92 -13.38   3.62 -10.68
```

```
> sum(x-xBar)      # skoraj nič :)
```

```
[1] -8.526513e-14
```

vector

```
> xq <- quantile(x,seq(0,1,.25))
> xq
     0%      25%      50%      75%     100%
149.900 160.375 166.650 170.425 184.100

> str(xq)
 Named num [1:5] 150 160 167 170 184
 - attr(*, "names")= chr [1:5] "0%" "25%" "50%" "75%" ..

> length(xq)
[1] 5
```

Izbor posameznih elementov

Posamezne elemente izberemo z navedbo indeksov v oglatih oklepajih `[...]`

```
> xq[2]   # drugi element
     25%
160.375
```

```
> xq[2:4] # kvartili
     25%      50%      75%
160.375 166.650 170.425
```

```
> xq[-1]  # brez minimuma
     25%      50%      75%     100%
160.375 166.650 170.425 184.100
```

Razrez podatkov

```
> par(mar=c(4,4,0,2))
> plot(sort(x))
> abline(h=xq,col="red")
```

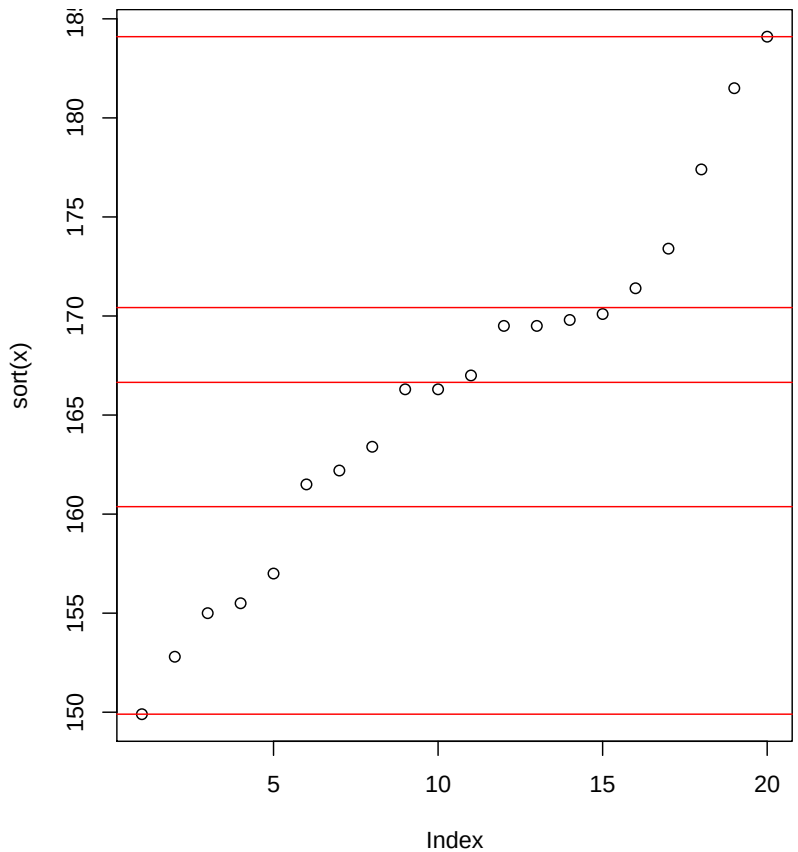

Uporaba vektorja

Razvrstitev v razrede z mejami **xq**

```
> xClass <- cut(x,xq)
> xClass
 [1] (150,160] (160,167] (170,184] (167,170] (150,160]
 [6] (160,167] (170,184] (167,170] (160,167] (170,184]
[11] (160,167] (170,184] <NA>      (160,167] (167,170]
[16] (167,170] (170,184] (150,160] (167,170] (150,160]
Levels: (150,160] (160,167] (167,170] (170,184]

> str(xClass)
 Factor w/ 4 levels "(150,160]","(160,167]",..: 1 2 4 3

> as.numeric(xClass)
 [1]  1  2  4  3  1  2  4  3  2  4  2  4 NA  2  3  3  4
[18]  1  3  1
```

Frekvenčna tabela

```
> tabela <- table(xClass,spol)
> dim(tabela)
```

```
[1] 4 2
```

```
> tabela
```

```
           spol
xClass      M Z
  (150,160] 0 4
  (160,167] 0 5
  (167,170] 2 3
  (170,184] 4 1
```

Pravokotne strukture

- `matrix` – 2 dimenziji
- `array` – več dimenzij
- `data.frame`

V matrikah so lahko le podatki enakega tipa (števila ali pa faktorji), v `data.frame` pa so lahko stolpci različnih tipov.

`data.frame` je klasična struktura statističnih podatkov: enote v vrsticah, spremenljivke v stolpcih (enake dolžine)

Izbira delov pravokotnih struktur

Iz pravokotnih struktur dobimo vrednosti z navedbo številke vrstice in stolpca, ...

```
> tabela[3:4, 1]

(167,170] (170,184]
        2         4

> tabela[ -4, ]    # brez četrte vrstice

            spol
xClass       M Z
  (150,160] 0 4
  (160,167] 0 5
  (167,170] 2 3

> tabela[ , 2]     # samo drugi stolpec

(150,160] (160,167] (167,170] (170,184]
        4         5         3         1
```

array

```
> array(letters,c(2,3,2))

, , 1

     [,1] [,2] [,3]
[1,] "a"  "c"  "e"
[2,] "b"  "d"  "f"

, , 2

     [,1] [,2] [,3]
[1,] "g"  "i"  "k"
[2,] "h"  "j"  "l"
```

list

Funkcija **hist** vrne uporabne informacije o histogramu

```
> opis <- hist(x,col="lightblue")
```

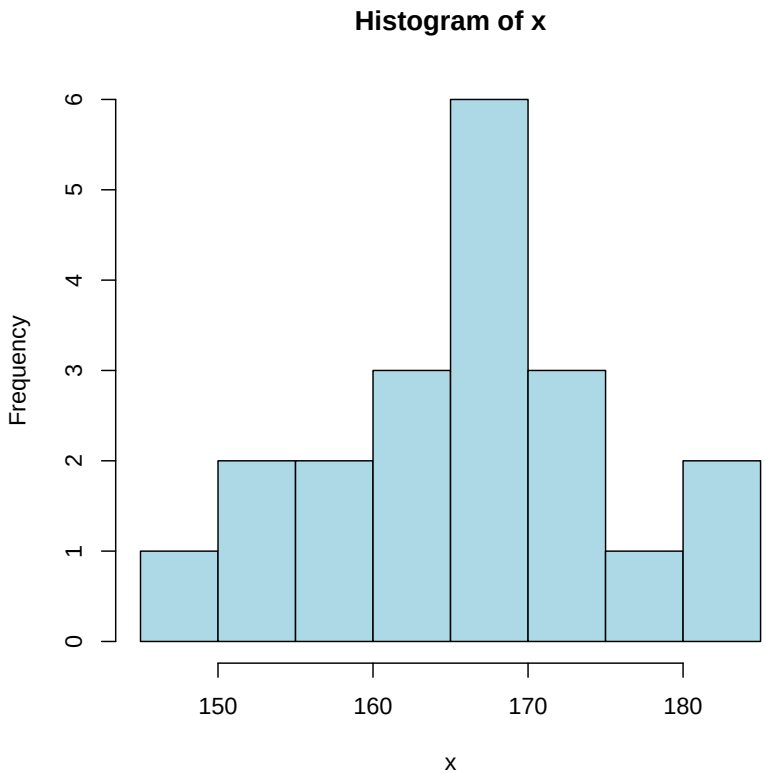

Struktura `list`

```
> names(opis)
[1] "breaks"      "counts"      "intensities"
[4] "density"     "mids"        "xname"
[7] "equidist"

> str(opis)
List of 7
 $ breaks     : num [1:9] 145 150 155 160 165 170 175 18
 $ counts     : int [1:8] 1 2 2 3 6 3 1 2
 $ intensities: num [1:8] 0.01 0.02 0.02 0.03 0.06 ...
 $ density    : num [1:8] 0.01 0.02 0.02 0.03 0.06 ...
 $ mids       : num [1:8] 148 152 158 162 168 ...
 $ xname      : chr "x"
 $ equidist   : logi TRUE
 - attr(*, "class")= chr "histogram"
```

Posamezni deli `list`

```
> names(opis)
[1] "breaks"      "counts"      "intensities"
[4] "density"     "mids"        "xname"
[7] "equidist"
```

Izbor komponente: z navedbo imena

```
> opis$counts
[1] 1 2 2 3 6 3 1 2
```

Izbor komponente: z navedbo številke komponente

```
> opis[[2]]
[1] 1 2 2 3 6 3 1 2
```

Dopolnjen histogram

Objekt **opis** vsebuje vse, kar rabimo za risanje (**class:histogram**)

```
> plot(opis,col="lightblue",main="Dopolnjen histogram")
> points(opis$mids,opis$counts,pch=16,col="red",cex=2)
> lines(opis$mids,opis$counts,col="blue",lwd=3,lty=2)
```