

# ITAP - Osnove uporabe R

A. Blejec

[andrej.blejec@nib.si](mailto:andrej.blejec@nib.si)

February 8, 2009

## Abstract

Osnove uporabe R .

## 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](mailto:andrej.blejec@nib.si)

# 1 Osnove

## 1.1

### 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**  $\pi$

**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"
[13] "as.Date.default"         "as.Date.factor"
[15] "as.Date.numeric"         "as.Date.POSIXct"
[17] "as.Date.POSIXlt"         "as.POSIXct.date"
[19] "as.POSIXct.Date"         "as.POSIXct.dates"
[21] "as.POSIXlt.date"         "as.POSIXlt.Date"
[23] "as.POSIXlt.dates"        "axis.Date"
[25] "c.Date"                  "cut.Date"
[27] "date"                    "dates"
[29] "diff.Date"                "format.Date"
[31] "is.numeric.Date"          "ISOdate"
[33] "ISODatetime"              "julian.Date"
[35] "Math.Date"                "mean.Date"
[37] "months.Date"              "Ops.Date"
[39] "print.Date"                "quarters.Date"
[41] "rep.Date"                  "round.Date"
[43] "seq.Date"                  "seq.dates"
[45] "split.Date"                "summary.Date"
[47] "Summary.Date"              "Sys.Date"
[49] "trunc.Date"                "update"
[51] "update.default"            "update.formula"
[53] "update.packages"           "update.packageStatus"
[55] "weekdays.Date"             "xtfrm.Date"

```

## 2 Podatkovne strukture

### 2.1 vector

#### vector

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

```

> c(1, 2, 3, 10, 20, 4)          # posamezne vrednosti lahko zlepim v vektor
[1] 1 2 3 10 20 4
> x <- c(1, 2, 3, 10, 20, 4)    # vektor shramim 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 komponente
[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 ponovijo
[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.out - 1)),
         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
> seq(1, 18, along=x)          # vzdolž vektorja x
[1] 1.0 4.4 7.8 11.2 14.6 18.0

```

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]          # četrти 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) | (or) in ! (not)
[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
```

## 2.2 matrix

Lepljenje vektorjev

```
> cbind(x, y, z)      # vektorje lahko zlepimo v tabelo, kot stolpce (c)
    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 stolpce)
[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 vektor
[1] 11 22 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 matriko,
[,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 ali stolpcov
[,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 napolnim po vrsticah
[,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

```

## 2.3 data.frame

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 stolpcov (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
```

## 2.4 list

Najbogatejša struktura: list

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

```

### 3 Vzorec podatkov

#### 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 spremenljivko

```

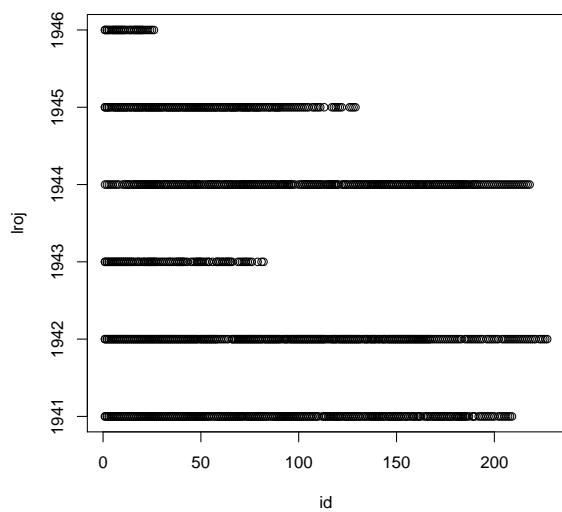
#### Vzorec

	<b>id</b>	<b>spol</b>	<b>lroj</b>	<b>starost</b>	<b>visina</b>	<b>teza</b>	<b>bmi</b>
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

Nenavaden **id**?

**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

```

## 4 Tipi rezultatov

### Vrste vrnjenih rezultatov

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

### 4.1 Vrednosti

#### 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

```

## 4.2 vector

vector

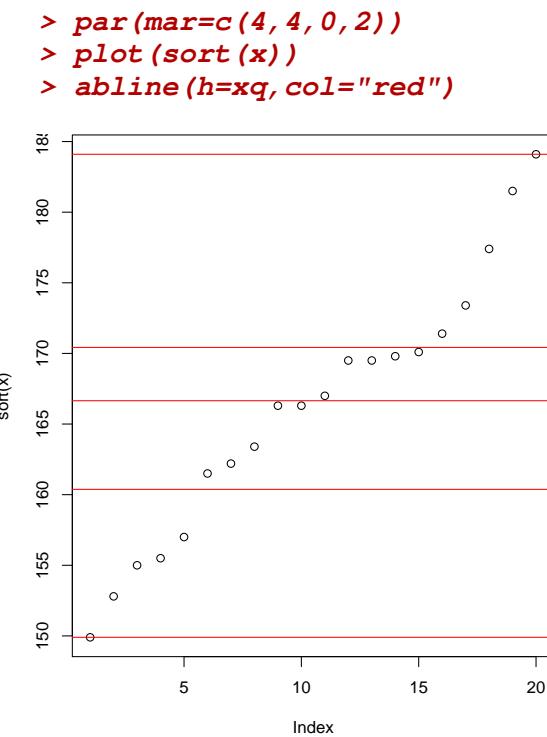
```
> xq <- quantile(x, seq(0, 1, .25))
> xq
    0%     25%     50%     75%   100%
149.900 160.375 166.650 170.425 184.100
> str(xq)
Named num [1:5] 150 160 167 170 184
 - attr(*, "names")= chr [1:5] "0%" "25%" "50%" "75%" ...
> length(xq)
[1] 5
```

### 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



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

```

## 4.3 matrix

### 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"

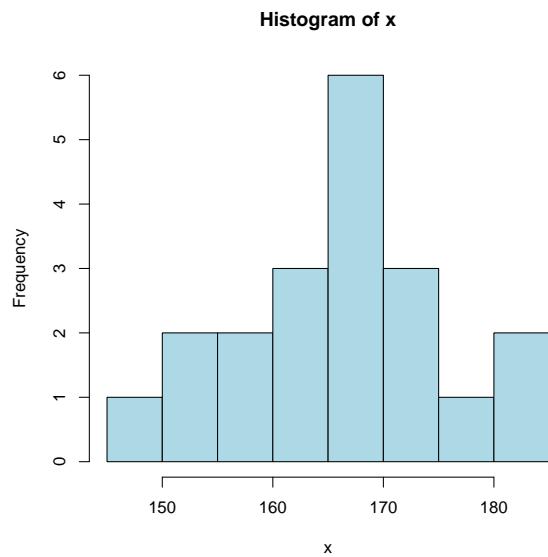
```

## 4.4 list

### 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] 145 150 155 160 165 170 175 180 185
$ 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)
```

