

Rakendustarkvara: R. Kevad 2018, 1. praktikum*

1 Lühike sissejuhatus

R on programmeerimiskeel ja -keskkond, mis on arendatud statistiliseks andmetöötluks. R-i kasutavate inimeste hulk on viimase kümmekonna aasta jooksul oluliselt kasvanud nii ülikoolides kui ka ettevõtetes¹. Eelkõige on populaarsuse põhjus vaba ligipääs, lai valik lisapakette ja kvaliteetsete jooniste tegemise võimalus.

R-i kodulehelt saab vajaliku tarkvara alla laadida: <http://www.r-project.org/>

1.1 Kasutajaliides

Programmil R on äärmiselt minimalistlik kasutajaliides. Programmi käivitades on näha ainult konsooliaken. Rea ees olev märk `>` näitab, et R ootab uut käsku. Käsud saab kirjutada sümboli `>` järele, sealjuures võib üks käsk paikneda mitmel järjestikusel real. Kui R-i arvates on käsu sisestamine pooleli, on konsoolirea alguses sümbol `+`, sel juhul võib käsu sisestamist uuest reast jätkata. Kui aga reavahetus on lisatud ekslikult, näiteks on koodis näha viga just eelnevas reas (mida pärast reavahetuse lisamist enam redigeerida ei saa) saab uue tühja käsurea tekitada vajutades **Esc** klahvi.

Kui käsk on sisestatud, siis **enter**-klahvi vajutamise järel käsk täidetakse ja tulemus trükitakse konsooliaknasse. Sageli on siis rea alguses kantsulgudes mingi arv, mis näitab, mitmes tulemuse element on rea alguses – nimelt võib tulemus mõnikord koosneda mitmest elemendist.

```
> 4 * 6
```

```
[1] 24
```

```
> 4 *
```

```
+ 6
```

```
[1] 24
```

```
> 4 * (1:40)
```

```
[1] 4 8 12 16 20 24 28 32 36 40 44 48 52 56 60 64 68
```

```
[18] 72 76 80 84 88 92 96 100 104 108 112 116 120 124 128 132 136
```

```
[35] 140 144 148 152 156 160
```

Kui konsooliaknas olles vajutada üles- või allanooleklahvi, saab sirvida eelnevalt täidetud käske.

Konsooli käskude sisestamise asemel on neid mõistlik kirjutada skriptifaili, et hiljem (nt järgmisel päeval) saaks tehtud tööd (näiteks mingi analüüsi) kiiresti jätkata või uuesti teha kui on lisandunud uued andmed. Skriptifaili tekitamiseks R-is tuleks valida menüüst **File** valik **New script**. Avatakse skriptiaken, kuhu saab käske kirjutada. Kui skriptiaknas olles vajutada klahve **Ctrl+R**, siis vastaval real olev käsk saadetakse R-ile täitmiseks. Kui käsk on kirjutatud mitmel real või on soov mitut käsku järjest jooksutada, võib vastavad read skriptiaknas hiirega ära märkida ning seejärel **Ctrl+R** vajutada. Valides menüüst **File** valiku **Save**, salvestatakse .R lõpuga skriptifail kasutaja poolt määratud asukohta.

*Praktikumijuhendid põhinevad aine MTMS.01.092 Rakendustarkvara: R (2 EAP) materjalidel, mille autorid on Mait Raag ning Raivo Kolde

¹<http://r4stats.com/articles/popularity/>

Sriptiaknas on mõislik käskudele lisada kommentaare, et teinekord või teisel inimesel oleks koodi lihtsam lugeda. **Kommentaare** saab R-i koodis lisada ainult rea lõpu, kasutades trellide-sümbolit:

```
log(5.9) # võtame naturaallogaritmi arvust 5,9
## [1] 1.774952
# terve see rida on kommentaar, sest rea alguses on # ehk trellide sümbol
```

Pane tähele, et **kümnendmurru eraldamiseks** kasutatakse R-is punkti, mitte koma.

Kahjuks on R-i kasutajaliides mõnevõrra ebamugav. Näiteks konsoliaknas ei saa hiirega kursori asukohta muuta. Samuti on kogu tekst sama värvi (koodi värvimine puudub). Üks alternatiivne kasutajaliides R-i kasutamiseks on **RStudio**², kus neid puuduseid pole ning millega on natuke hõlpsam koodi kirjutada.

1.2 Lihtsam aritmeetika

R-is on võimalik teha kõiki lihtsamaid aritmeetilisi tehteid, sealjuures järgitakse matemaatikas kasutatavat tehete järjekorda (sulgusid lisades on võimalik seda muuta):

- $1 + (2 - 3) * 4 / 5$
- $2^3 - 2 * 3$ – astendamiseks saab kasutada sümboleid `^` ja `**`
- $5 \% 3$ – modulo (jääk jagamisel)
- $\log(\exp(1)) * \cos(-\pi) * \sqrt{9} + \text{factorial}(4) - \text{choose}(4, 2) * \min(4, 5, 2)$
on sama, mis $\ln(e^1) \cdot \cos(-\pi) \cdot \sqrt{9} + 4! - \binom{4}{2} \cdot \min(4, 5, 2)$
- 1/0 annab tulemuseks **Inf** (*infinity*)
- 0/0 annab tulemuseks **NaN** (*not a number*)

1.2.1 Ülesanded

1. Arvuta enda kehamassiindeks: $\text{kaal (kg)} / \text{pikkus}^2 \text{ (m}^2\text{)}$. (Õppejõule ei pea näitama.)

1.3 Käsud ja abi saamine

Ülalolevad aritmeetikaavaldised `sqrt(9)`, `choose(4, 2)` jne on tegelikult **käsud** ehk **funktsioonid**, mis oskavad teatud asju teha (praeguses näites teatud arvutusi teha). Kõigil käskudel on sarnane süntaks:

`kask(argumentid)`

Üldiselt on käsu argumentidel ka nimed, näiteks käsk `choose` tahab täpselt kahte argumenti: `n` ja `k`. Mõnikord on kasulik argumentide nimed välja kirjutada, et hiljem koodi üle lugedes oleks aru saada, mida miski tähendab:

```
choose(n = 4, k = 2)
```

Kui kasutada argumentide nimesid, siis ei ole tähtis, millises järjekorras argumentid käsule ette anda. Ent kui argumentide nimesid ei kasuta, tuleb olla ettevaatlik:

```
choose(k = 2, n = 4)
```

```
## [1] 6
```

```
choose(2, 4)
```

```
## [1] 0
```

²<http://www.rstudio.com/>

Osadel käskudel on mõnede argumentidele antud niinimetatud vaikimisi väärtused. Neid argumente ei pea (aga võib) käsu kasutamisel välja kirjutama kui vaikimisi argument on parajasti sobiv väärtus. Näiteks on käsul `log` vaikimisi määratud argumenti `base` ehk logaritmi aluse väärtus arvuga $e \approx 2.718282$ st käsk arvutab naturaalogaritmi. Kui on soov leida naturaalogaritmi arvust 8, siis võib käsu kirja panna `log(8)`, kui aga on vaja leida arvu 8 logaritmi baasil 2, siis tuleks argumenti `base` vaikimisi väärtust muuta, ehk

```
log(8, base = 2)
```

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

Kui mingi konkreetse käsu kohta soovitakse abi saada (näiteks kontrollida, mis on käsu argumentide nimed ja millises järjekorras need tuleks ette anda), võib konsooli trükkida `?käsu_nimi` või ka `??otsitav_tekst:`

```
?choose
```

```
??"logarithm"
```

Tasub tähele panna, et R on (nagu suurem osa programmeerimiskeeli) **tõstutundlik** – see tähendab, et programm eristab suuri ja väikeseid tähti. Kui ajada käsu või argumenti nimes mõni suur- ja väiketäht segi, siis on tulemuseks veateade:

```
Log(5)
```

```
## Error in Log(5): could not find function "Log"
```

```
log(8, BASE = 2)
```

```
## Error in log(8, BASE = 2): unused argument (BASE = 2)
```

1.3.1 Ülesanded

1. Vaata, kuidas töötab käsk `log10`, mis on selle argumentid.
2. Vaata milline abileht avaneb, kui kasutada käsku `?"*"`.
3. Leia funktsioon, mis arvutaks nurga $\pi/2$ siinuse.

2 Muutujatega töötamine

2.1 Väärtuste omistamine ja töökeskkond (*environment*)

Sageli on mugav, kui töös kasutatavatele muutujatele nimi anda – siis saame neid edaspidi nimepidi kutsuda. Näiteks kui nimetada `kaal <- 70` ja `pikkus <- 185` ehk konsoolil

```
kaal <- 70
```

```
pikkus <- 185
```

siis saaks kehamassiindeksit arvutada nii:

```
kaal / (pikkus / 100)**2
```

```
## [1] 20.45289
```

Tekitasime esimesel sammul töökeskkonda kaks objekti, mille nimed on `kaal` ja `pikkus`. Täpsemini: tekitasime objektid `kaal` ja `pikkus`, millele omistasime väärtused 70 ja 185. Sümboliühendit `<-` nimetatakse omistamisoperaatoriks. Üldjuhul töötab omistamisoperaatorina ka võrdusmärk `=`, ent on mõned erandjuhtumid, kus need erinevalt töötavad; lisaks on võrdusmärk kasutusel käskude argumentidele väärtuse andmisel.

Kui nüüd muuta `kaal` väärtust: `kaal <- 90`, siis konsoolis ülesnoolega üle-eelmise käsu (KMI arvutamise) üles otsides saab seda lihtsasti uuesti jooksutada.

```
kaal / (pikkus / 100)**2
```

```
## [1] 26.29657
```

Siit maksab tähele panna ka seda, et muutujale uut väärtust omistades kirjutatakse vana lihtsalt üle, mingit hoiatust R ei anna.

Töökeskonnas olevatest objektidest saab ülevaate käsuga `ls()`. Töökeskonnas olevaid objekte saab kustutada käsuga `rm(.)` (sulgudes olev punkt asendada sobivate argumentidega):

```
rm(kaal, pikkus)
ls() #kontrolli, kas objektid kustutati töölaualt
```

Lisaks skriptifailile on võimalik ka töökeskonda salvestada ning hiljem see uuesti sisse laadida. Selleks peab R-is konsooliakna aktiivseks tegema ja valima menüüst **File** vastavalt **Save workspace** või **Load workspace**. RStudios leiab need toimingud aga menüüst **Session**. Käsurealt on töökeskonda võimalik salvestada RData failiks käsuga `save.image()`.

Töökeskonna salvestamisel salvestatakse kõik antud töökeskonnas olnud objektid RData-faili. Hiljem saab kõik need objektid jälle RData failist töökeskonda laadida käsuga `load(".RData")`. RData formaati üldiselt teised statistikaprogrammid lugeda ei oska. Kui salvestatud on käskude ehk skriptifail (laiendiga `.R`), siis objektide eraldi salvestamine pole enamasti vajalik.

2.2 Vektorid. Tehted vektoritega

Eelmises punktis vaatasime juhtu, muutujate väärtuseks oli üks arv. Objekti võib aga moodustada ka mitmest väärtusest, näiteks omistame kuue uuritava kaalud muutujale nimega `kaalud` ja muutujale `liik` uuritavate liigid:

```
kaalud <- c(7, 3.5, 0.4, 2, 3.2, 20.2)
liik <- c("koer", "kass", "roott", "kass", "kass", "koer")
```

Funktsiooni `c(.)` korral on tegemist käsuga, mis sellele antud argumentid kombineerib (*combine*) kokku üheks vektoriks (järjendiks). Kui kombineeritakse erinevat tüüpi väärtuseid (näiteks teksti ja arve), siis muudetakse kõik väärtused selliseks, mis võimaldab võimalikult palju infot säilitada – kõik vektori elemendid peavad olema sama tüüpi.

```
c(987, -Inf, "jutumärgid", kaalud) # pane tähele jutumärke allolevas väljatrükis
```

```
## [1] "987"          "-Inf"          "jutumärgid"   "7"            "3.5"
## [6] "0.4"          "2"            "3.2"          "20.2"
```

Kindla mustriiga arvujada tekitamiseks on ka muid mooduseid kui funktsioon `c`:

```
1:5 # täisarvud 1-st 5-ni
```

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

```
2:-6 # täisarvud 2-st -6-ni
```

```
## [1] 2 1 0 -1 -2 -3 -4 -5 -6
```

```
seq(from=0, to=11, by=2) #arvud 0, 0+2, 0+2+2, ..., kuni jõutakse väärtuseni 11
```

```
## [1] 0 2 4 6 8 10
```

```
seq(0, 1, 0.1) # saab ka komaga arvudest järjendeid teha
```

```
## [1] 0.0 0.1 0.2 0.3 0.4 0.5 0.6 0.7 0.8 0.9 1.0
```

```
seq(0, 1, length.out=4)
```

```
## [1] 0.0000000 0.3333333 0.6666667 1.0000000
```

```
rep(x=c(1, 3), times=2) # vektorit korratakse 2 korda
```

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

```
rep(x=c(1, 3), each=2) # vektori iga elementi korratakse 2 korda
```

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

Käsku `rep(.)` saab kasutada ka sõnede kordamisel: `rep(c("a", "b", "c"), c(3, 2, 0))`.

R-i puhul on huvitav see, et sageli tehakse mitmesuguseid tehteid elemendiviisiliselt. Mõnikord tasub olla ettevaatlik: kui asjaosalised vektorid on erineva pikkusega, siis lühemat pikendatakse automaatselt `rep(.)` käsu laadselt

```
1:3 * 4 # iga element korrutatakse 4-ga läbi
```

```
## [1] 4 8 12
```

```
1:3 + 9:7 # elemendid liidetakse paarikaupa
```

```
## [1] 10 10 10
```

```
1:6 * c(1, 2) # iga teine element korrutatakse 2-ga, ei hoiatata
```

```
## [1] 1 4 3 8 5 12
```

```
1:7 * c(1, 2) # antakse küll hoiatus, aga 7. element korrutatakse 1-ga
```

```
## Warning in 1:7 * c(1, 2): longer object length is not a multiple of shorter
```

```
## object length
```

```
## [1] 1 4 3 8 5 12 7
```

Sageli on andmevektorist vaja kasutada vaid mingit alamosa, näiteks tahame kasutada ainult esimest kolme vaatlust või iga teist vaatlust. Vektorist elementide väljavaliuks saab kasutada kantsulge: kirjutada vektori nime järgi kantsulud ja sulgudes anda ette milliste indeksitega elemente välja valida soovime st esitada indeksite vektor. Elementide numeratsioon ehk indeksid algavad R-is väärtusest 1

```
kaalud[1:3] # esimesed 3 elementi vektorist
```

```
## [1] 7.0 3.5 0.4
```

```
kaalud[seq(1, 6, 2)] # iga teine element alates esimesest
```

```
## [1] 7.0 0.4 3.2
```

```
(1:10)[-c(2, 4)] # negatiivne indeks jätab vastavad vaatlused välja
```

```
## [1] 1 3 5 6 7 8 9 10
```

2.2.1 Ülesanded

1. Moodusta vektor nimega `y`, mille väärtuseks oleks arvud `1 1 1 2 2 2 2 3 3 3 3 3` kasutades käsku `rep`.
2. Leia vektor `z`, mille liitmisel `y`-le on tulemuseks vektor, mille kõik koordinaadid on võrdsed 7.
3. Vali eelnevast vektorist välja iga kolmas väärtus, kasutades kantsulge ja sobivat indeksite vektorit.
4. Omista muutujale `u` väärtus 8. Proovi läbi käsud `1:u - 1` ja `1:(u-1)`. Milles on erinevus?

2.3 Puuduvad väärtused

Andmete kogumisel võib juhtuda, et kõigil uuritavatel ei õnnestu vajalikke mõõtmisi teha ja andmetesse tekivad lüngad. Puuduva väärtuse tähistamiseks on R-is tähekombinatsioon `NA` (*Not Available*). Oletame, et analüüsil on vaja teada ka uuritavate vanust, teise vaatlusaluse kohta pole aga see teada:

```
vanused <- c(7, NA, 3, 53, 53, 95)
```

```
vanused
```

```
## [1] 7 NA 3 53 53 95
```

Kui teha arvutusi puuduva väärtusega, siis tulemuseks on samuti puuduv väärtus. Proovi:

```
123 + NA
## [1] NA
# vanuste vektor teisendada aastateks ja ümardada
round(vanused/12, 1)
## [1] 0.6 NA 0.2 4.4 4.4 7.9
R-i funktsioonidel võivad olla lisaargumendid, mis reguleerivad puuduvate väärtusega toimetamist:
mean(vanused) # keskmine vanus, kui kaasta NA väärtus on NA
## [1] NA
mean(vanused, na.rm = TRUE) # keskmine vanus, kui NA väärtus on eemaldatud
## [1] 42.2
table(vanused) # vanuste sagedustabel, NA väärtust ei esitata
## vanused
## 3 7 53 95
## 1 1 2 1
table(vanused, useNA = "ifany") # lisame sagedustabelisse ka puuduva väärtuse, kui esineb
## vanused
## 3 7 53 95 <NA>
## 1 1 2 1 1
table(liik, useNA = "always") # lisame sagedustabelisse ka puuduva väärtuse, alati
## liik
## kass koer rott <NA>
## 3 2 1 0
summary(vanused) # NA väärtuste arv tuuakse vaikimisi välja
## Min. 1st Qu. Median Mean 3rd Qu. Max. NA's
## 3.0 7.0 53.0 42.2 53.0 95.0 1
```

2.3.1 Ülesanded

1. Kuidas käitub funktsioon `sum(.)` kui argumendiks satub puuduvate väärtustega vektor?
2. Kas funktsioonil `which.min(.)` on lisaargument, mis reguleerib puuduvate väärtustega tegelemist?