Sissejuhatus

Statistiliste meetodite kiire areng ja laialdane kasutuselevõtt on teoks saanud suuresti tänu arvutustehnika arengule. Esimeste arvutite valmimisel alustati tööd ka statistikatarkvara loomiseks.

Vajalike statistiliste arvutuste tegemiseks kirjutati esmalt eriotstarbelisi programme. Aja möödudes, kui programmikesi oli juba ohtrasti, koondati nad kokku statistikapakettidesse. Tulemuseks oli statistikavahendite tekkimine, mis lahendasid üht- või teist ülesannet küll efektiivselt, kuid programmi erinevate osade koostööle sundimine võis nõuda kangelaslikke pingutusi. Samuti oli (on) taoliste statistikaprogrammide täiendamine enamasti keerukas ja eelkõige spetsiaalselt programmi hooldava ja täiendava (kinnise) meeskonna töö.

Taolise kaootiliselt tekkiva statistikatarkvara taustal tulid kokku mõned andekad inimesed (Richard A. Becker, John M. Chambers jt.) ning unistasid statistikule meelepärasest töökeskkonnast, kus kõik üksikosad töötaksid harmooniliselt koos. Oma unistuse panid nad kirja ja avaldasid S-keele kirjelduse nime all 1984. aastal. Hiljem on S-keele definitsiooni mitu korda täiendatud ja parandatud.

Teoreetilisest kirjeldusest haarasid kinni erinevad meeskonnad ja üritasid selle põhjal luua töötavat arvutiprogrammi. Tänases maailmas on laialt levinud kaks S-keele definitsiooni põhjal loodud programmi: suure raha eest müüdav S-Plus ja tasuta jagatav R. Viimast hakkasid vabatahtlikud huvilised kirjutama 1997. aastal, 2000. aasta kevadel jõuti esimese versioonini (R 1.0); hetkel (oktoober 2007) viimane versioon on 2.6.0. Põhiosa värskendamine (versiooniuuendus) leiab ligikaudu aset kaks korda aastas.

Kuidas saada endale R?

R on vaba tarkvara. Uusima versiooni programmist võib maha laadida R-i koduleheküljelt **http://www.r-project.org/** (*Download-CRAN* – <vali server> – *Windows* – *base*). Samuti võib R-i koduleheküljelt leida ka ingliskeelse raamatu algajaile (*Help – Manuals – An Introduction to R*) ja spetsiaalsete ülesannete jaoks loodud statistikamooduleid, mis vaikimisi koos R-iga ei installeeru (hetkel saadaval rohkem kui 500 lisamoodulit, näiteks nagu moodul norm puuduvate vaatlustega andmestike analüüsimiseks või geenide klasterdamiseks mõeldud moodul GeneSOM). Programmi R peaks praegu olema võimalik kasutada Windowsi, Linuxi, Macintoshi, Sun Solarise jpt. operatsioonisüsteemide peal. Standardinstallatsioon võtab umbes 60 Mb ruumi, koos täiendavate lisamoodulitega rohkem (täiskomplekt üle 600 Mb). On olemas ka miniversioon, mis saab hakkama ka paar korda väiksema kettaruumiga. Teoreetiliselt võiks R Windowsi keskkonnas hakkama saada andmestikega mis on kuni 1,5Gb suured, kuid töö väga suurte andmestikega on R-is hetkel siiski problemaatiline.

Kirjandust

Põhjalikumat ülevaadet kui käesolev sissejuhatav material pakkuda suudab võib leda järgmistest allikatest:

- www.r-project.org alt on võimalik leida algajaile mõeldud raamatut (*Help – Manuals – An Introduction to R*). Soovitav on iseseisvalt läbi proovida peatükis *Sample session* toodud käsud.
  R´i koduleheküljelt on võimalik kätte saada ka mitmeid teisi asjalikke raamatuid, vaata menüüd *Documentation-Contributed*.
- Peter Dalgaard (2002). *Intrductory Statistics with R.* Springer-Verlag. Heas stiilis raamat ühelt R-i loojatest.
- http://www.ms.ut.ee/mart/R/Rgraafika.html – näited graafikute joonistamisest R-is.

Alustuseks

R kui kalkulaator

R oskab arvutada. Seda väidet saab kontrollida, sisestades näiteks järgmine käsk (viipa „>“ pole tarvis sisestada, rea lõpus vajutage ENTER-klahvile):

```
> (2+3)*6
[1] 30
```

Tehteid saab teha (ja paljusid funktsioone kasutada) ka tervete arvujadadega ehk vektoritega korraga. Järgmise käsuga palume ruutjuured arvudest ühest kümneni:

```
> sqrt(1:10)
 [1] 1.000000 1.414214 1.732051 2.000000 2.236068 2.449490 2.645751 2.828427
 [9] 3.000000 3.162278
```

Näiteid käskudest ja funktsioonidest, mida R tunneb:

`> 2**8 või 2^8` – astendamine, 2^8;
`> sin(0.5*pi)` – näide trigonomeetrilise funktsiooni kasutamisest;
`> log(exp(10))` – funktsioon log leiab naturaallogaritmi arvust;

Muutujad

Ka kalkulaatorit kasutades tekib peatselt vajadus meeles hoida arvutuste tulemusi. R´is, nagu paljudes teistes programmeerimiskeelteski, võib kasutada sümboleid või sõnu (objektide nimesid) väärtuste hoidmiseks. Näiteks saab omistada *x*-le väärtuse 3 järgmise käsu abil:

```
> x=3
```

Selle käsu saamisel teostab R omistamise. Kui kõik läheb hästi, ei ilmu sealjuures ekraanile midagi. Edaspidi saab juba oma töös kasutada *x*-i samamoodi kui numbrit 3:

```
> x
[1] 3
> x+5
[1] 8
```

Meelde jätta võib muudki, kui vaid ühte arvu – *x* võib olla näiteks terve arvude vektor (kümne hiire kaalud); andmestik (saja katsehiire nimed, kaalud, pikkused, geneetiliste markerite väärtused,...); regressioonanalüüsi tulemused koos jääkide, hinnatud parameetrite väärtuste ja muu juurdekuuluvaga; samuti võib ta olla funktsioon, mis arvutab Gini kordajat ja palju muudki.

Seda, milliseid nimesid oled objektide tähistamiseks kasutanud, saab vaadata käsu *ls()* abil:

```
> ls()
[1] "x"
```

Kasutu objekti võib kustutada käsuga *rm()*:

```
> rm(x)
```

R lubab omistamisel kasutada ka tema enda käskude nimesid. Juhul, kui R'i mõni käskudest ümber defineeriteakse, võib tulemuseks olla palju segadust. Sestap tuleks võimaluse korral vältida R´i käskude („*c*“, „*t*“, „*lm*“, „*ls*“ jne) kasutamist muutujanimedena. Muutujate nimedeks sobivad hästi näiteks eestikeelsed salvestatud objekti kirjeldavad sõnad (RebasteArv, mudel2 jne).

Tähtis! R teeb vahet suurte ja väikeste tähtede vahel. Seega on „x“ ja „X“ kaks erinevat objekti. Samuti annab käsk *SQRT*(2) veateate, sest ruutjuure leidmise funktsioon on *sqrt* (väikesed tähed!).

Abiinfo (help)

Juhul, kui tead küll funktsiooni nime, mida kasutada soovid, kuid sooviks siiski täiendavat informatsiooni tema kohta, tipi „?“ ning sind huvitav funktsioon sinna järgi:

```
> ? median
```

R näitab seepeale antud käsu süntaksit ja näiteid sisaldavat ekraani.

Programmi kirjutamine ja tehtud töö dokumenteerimine

Soovitav on R-i programm enne kasutamist valmis kirjutada mõnes tekstieditoris (näiteks notepadis) ja alles siis käsud lõika-kleebi abil R-i täitmiseks tõsta. See võimaldab ühelt poolt vigade olemasolul vigu kergesti parandada ja uuesti katsetada, teiselt poolt võimaldab tehtavat tööd dokumenteerida. Saab kasutada ka R-i enda editori (*File -> New Script*), millisel puhul saab valmiskirjutatud programmi kergesti käivitada – vali vaid programmilõik mida käivitada soovid ja vajuta CTRL+R.

Kõiki töö käigus R-le antud käske saab salvestada valides menüüst *File -> Save History*. Peale salvestamist tekib *.Rhistory* –lõpuga tekstifail, mida saab tekstieditoriga (näiteks notepad) avada ja redigeerida. Antud hetkeni R-le antud käsud koos vastustega saab tekstifaili salvestada valides menüüst *File->Save to File*.

Kõiki töö käigus tehtud muutujaid, andmestikke jms saab korraga salvestada valides menüüst *File -> Save Workspace*. Kogu tekitatud muutujate, andmestike ja muu töökeskkonna saab siis hiljem taastada valiku *Load Workspace* abil.

Vaikimisi salvestatakse ja hakatakse faile otsima töökataloogist. Mõistlik on teha iga projekti (näiteks Monte-Carlo meetodite kursuse) jaoks oma alamkataloog ja tööd alustades seada töökataloog viitama mainitud kataloogile. Seda saab teha kas valides menüüst käsu *File -> Change dir* või kasutades käsku *setwd*.

Ülesanded

1. $\frac{1}{1+0{,}00022} - (1 - 0{,}00022) = ?$
2. $1{,}79451+1{,}79451^{1{,}79451}+\sin(1{,}79451) = ?$
3. Uuri välja, mida teeb funktsioon *apropos* – alustuseks proovi näiteks *apropos("cos")*.

Andmed ja nende vaatamine

Andmestikke, muutujaid ja muud (näiteks hinnatud mudeleid jms) saab salvestada ja taas lugeda käskude *save* ja *load* abil. Oleks meil olemas andmestikud andmestik1 ja *andmestik2*, saaksime need salvestada faili *minu* järgmise käsu abil:

> save(andmestik1, andmestik2, file="c:/minu")

Failis „minu“ olevaid objekte (andmestike, muutujaid jms) saab lugeda R-i järgmisel viisil:
> load("c:/minu")

NB! Pange tähele – R-is tuleb failiteed anda nn UNIX'i stiilis, st tagurpidi kaldkriipse (/) kasutades. Alternatiivina võib kasutada ka kahekordseid kaldjooni (\\).

Alustuseks loeme aga sisse ühe pärisandmestiku – Tartu Ülikooli meditsiiniteaduskonna tudengite küsitluse andmed (andmestik kokku):

```
> load(url("http://www.ms.ut.ee/mart/MC2007/kokku.Rdata"))
```

Antud küsitluse ankeeti võite näha aadressil
http://www.ms.ut.ee/mart/MC2007/ankeet.pdf

Andmed on nüüd R-is, aga kuidas neid näha?
Võimalused:

1. tippige R-i andmestiku nimi (vajadusel vaadake *ls()*-käsu abil, mis nimega andmestikud/objektid tekkisid R-i peale load-käsku!):

   ```
   > kokku
   ```

   Andmestik jookseb silme eest mööda, aga eriti targemaks vist ei saanud?
2. Andmeid saab vaadata ja muuta ka *edit*-käsu abil. Vaatamiseks:

   ```
   > edit(kokku)
   ```

   Muutmiseks (muudetud andmestik salvestatakse nime *kokku2* all, esialgne andmestik *kokku* jääb ka alles):

   ```
   > kokku2 = edit(kokku)
   ```

3. Andmestikus sisalduvate tunnuste nimesid saab vaadata ka käsu *names()* abil:

```
> names(kokku)
 [1] "aasta"         "vanus"         "sugu"          "perekonnaseis"
 [5] "toop.ohk"      "puhkep.ohk"    "sport"         "suitsetamine"
 [9] "olu"           "vein"          "viin"          "tervis"
[13] "viirus"        "kiirabi"       "haiglaravi"    "toolt.puudu"
[17] "pikkus"        "kaal"          "SVR"           "DVR"
```

4. Võime ka välja trükkida paar esimest (funktsioon *head*) või viimast (funktsioon *tail*) kirjet:

```
> tail(kokku)

    aasta vanus sugu perekonnaseis toop.ohk puhkep.ohk sport
656  2001    27    1             2       NA         NA     2
657  2001    20    1             1       NA         NA     2
658  2001    19    1             1       NA         NA     2
659  2001    19    1             1       NA         NA     2
660  2001    19    1             1       NA         NA     2
661  2001    20    1             1       NA         NA     2
    suitsetamine olu vein viin tervis viirus kiirabi haiglaravi
656            1   1    3    2      3      1      NA         NA
657            1   1    2    1      1      3      NA         NA
658            1   1    2    3      2      4      NA         NA
659            1   1    2    2      2      4      NA         NA
660            1   2    3    2      3      1      NA         NA
661            1   3    3    2      3      1      NA         NA
    toolt.puudu pikkus kaal SVR DVR
656          NA  173.0 73.0 120  83
657          NA  166.5 57.5 114  76
658          NA  167.0 52.0 100  88
659          NA  182.5 74.0 127  88
660          NA  170.0 63.0 111  76
661          NA  154.0 51.0 108  63
```

5. Samuti võime andmestikust kiirülevaate saada *summary*-käsu abil, proovi näiteks käsku *summary(kokku)*.

Andmete väljanoppimine andmestikust

Ühe tunnuse väärtuseid saab kätte kasutades süntaksit <andmestiku nimi>$<tunnuse nimi>; näiteks tudengite kaalude vaatamiseks kirjuta:

```
> kokku$kaal
```

ja tudengite pikkuste histogrammi saamiseks kasuta:

```
> hist(kokku$pikkus)
```

Samuti saab andmeid välja nõuda kasutades indekseid. Proovi, mida teevad järgmised käsud:

```
kokku[1,]
kokku[1,2]
kokku[1:5,]
kokku[,2]
kokku[kokku$pikkus>195,]
kokku[kokku$sugu==1 & kokku$pikkus>180,]
```

Kui töötame pidevalt ühe ja sama andmestikuga, on iga tunnuse ette andmestiku nime kirjutamine tülikas. Selle vältimiseks saame R-le öelda, millise andmestikuga me parajasti töötame – seda saab teha *attach()* käsku kasutades:

```
> attach(kokku)
```

Peale attach-käsku võime tunnuste poole pöörduda ka ilma andmestiku nime täpsustamata:

```
> table(sugu)
sugu
  1   2
512 149
```

Kui oleme töö oma andmestikuga lõpetanud (näiteks soovime hakata töötama mõne teise andmestikuga) tuleks varemkasutatud andmestik „lahti ühendada“ käsu *detach()* abil. Peale *detach()*-käsu andmist saab andmestikus olevate tunnuste poole pöörduda vaid „täisnime“ – *andmestikunimi**$**tunnusenimi* – kasutades.

```
> detach(kokku)
> table(sugu)
Error in table(sugu) : object "sugu" not found
> table(kokku$sugu)
  1   2
512 149
```

Antud materjalis toodud näidete läbimiseks attach-ige andmestik kokku tagasi.

Puuduvad väärtused

Puuduva väärtuse tähis R-is on NA (Not Available). R käsitleb kohati puuduvaid väärtuseid peaaegu segavalt korrektselt:

```
> mean(pikkus)
[1] NA
```

Sest osade tudengite pikkus pole teada, ja seega pole võimalik leida ka tudengite keskmist pikkust – keskmine pikkus on puuduv väärtus. Osad funktsioonid võimaldavad leida otsitava statistiku väärtuse kasutades vaid olemasolevaid väärtuseid, kui lisame lisaparameetri *na.rm=T*:

```
> mean(pikkus, na.rm=T)
[1] 171.1167
```

Samuti võime luua uue andmestiku, kust on eemaldatud need tudengid, kelle pikkust või kaalu pole teada:

```
> tudengid=kokku[!is.na(pikkus)&!is.na(kaal),]
```

ning edasi võime analüüsida juba olemasolevaid vaatluseid sisaldavat andmestikku:

```
> detach(kokku); attach(tudengid)
> mean(pikkus)
[1] 171.1052
```

Põhistatistikud

Põhistatistikute leidmine on imelihtne. Järgnevalt leiame kõigi tudengite keskmise pikkuse, 2001.a küsitletud tudengite keskmise pikkuse ja keskmise pikkuse küsitlusaasta järgi:

```
> mean(pikkus)
[1] 171.1052
> mean(pikkus[aasta==2001])
[1] 170.8861
> by(pikkus, aasta, mean)
INDICES: 2001
[1] 170.8861
------------------------------------------------------------
INDICES: 2002
[1] 170.981
------------------------------------------------------------
INDICES: 2003
[1] 171.4079
------------------------------------------------------------
INDICES: 2004
[1] 171.1837
```

Pideva või diskreetse tunnuse jaotust iseloomustavaid statistikuid saab leida näiteks järgmiste funktsioonide abil:

`length(pikkus)` – vaatluste arv (vektori pikkus)
`min(pikkus)` – miinimum
`max(pikkus)` – maksimum
`range(pikkus)` – miinimum ja maksimum
`mean(pikkus)` – keskmine
`median(pikkus)` – mediaan
`sd(pikkus)` – standardhälve
`var(pikkus)` – dispersioon (kasutatav ka kovariatsiooni leidmiseks)
`quantile(pikkus, 0.13)` – 0.13-kvantiil
`summary(pikkus)` – lühiiseloomustus (miinimum ja maksimum, alumine ja ülemine kvantiil, mediaan)
`cor(pikkus, kaal)` – pikkuse ja kaalu vaheline korrelatsioonikordaja

Ülesanded

Ülesanne 1
Tunnus *olu* näitab, mitu pudelit õlut tudeng nädala jooksul ära joob:
1 - mitte kunagi
2 - vähem kui pudel nädalas (1 pudel = 0,33 l)
3 - 1-4 pudelit nädalas
4 - 5-12 pudelit nädalas
5 - 13-või rohkem pudelit nädalas

1. Leia sagedustabel. Kas tudengid joovad palju?
2. Nuputa välja, mida arvutab järgmine käsk:
   `prop.table(table(olu))*100`
3. Leia õlut mittetarbivate tudengite keskmine pikkus; alla pudeli nädalas joovate tudengite keskmine pikkus jne. Mida märkad? Kas õlut joovad tudengid on pikemad või lühemad kui õlut mittejoovad tudengid? Kuidas seletad/põhjendad nähtud tulemust?

Ülesanne 2
Leia tudengite keskmine kaal ja kaalude mediaan. Kumb tuleb suurem? Miks? Selgituse otsimisel võid vaadata ka tudengite kaalude histogrammi. Selle saad sisestades käsu: `hist(kaal)`

Ülesanne 3
Tunnus haiglaravi näitab, kas tudeng on viimase kahe aasta jooksul vajanud haiglaravi. Nendel tudengitel, kes haiglasse pole sattunud, on haiglaravi=0. Kes aga on kahe aasta jooksul haiglas viibinud, neil on haiglaravi=1. Leia tunnuse haiglaravi keskmine. Mida tavakeeles öeldult leitud keskmine näitab?

Ülesanne 4
Millise käsu abil saaks kätte kolme esimese tudengi andmed?

Andmete sisestamine klaviatuurilt/programmist

Vahel soovime mõningaid väärtuseid ka käigupealt sisestada. Lihtsaim viis vaatluste (või arvujada) sisestamiseks on kasutada funktsiooni *c*. Loome vektori *h* mis sisaldab viie puu kõrguseid:

```
> h = c(20, 12, 14, 16, 33)
> h
[1] 20 12 14 16 33
```

Andmed, mida vektoris hoitakse, ei pea olema arvulised. Me võime tekitada ka vektori, mis sisaldab uuritud puude liigilist kuuluvust näitavaid andmeid:

```
> liik = c("Kuusk", "Kask", "Kask", "Kask", "Kuusk")
> liik
[1] "Kuusk" "Kask"  "Kask"  "Kask"  "Kuusk"
```

Üks võimalus andmemaatriksit luua on teha seda kasutades olemasolevaid vektoreid ehk üksiktunnuste väärtuseid. Üksiktunnused saab andmestikuks kokku panna *data.frame* käsu abil:

```
> minuandmed=data.frame(liik, h)
> minuandmed
   liik  h
1 Kuusk 20
2  Kask 12
3  Kask 14
4  Kask 16
5 Kuusk 33
```

Väärtuste automaatne genereerimine

Vahel tekib vajadus kiiresti genereerida tunnuse väärtused mingi kindla skeemi kohaselt. Näiteks järjestikustest arvudest koosnevat vektorit saab tekitada järgmise käsu abil:

```
> 3:10
[1]  3  4  5  6  7  8  9 10
```

Näiteid kasutamisest:

```
h[1:3]
for(i in 1:10) {print(„R on kole keeruline“)}
```

Käsuga seq saab tekitada järjestikuseid arve mingi etteantud sammuga:

```
> seq(6,10,0.5)
[1]  6.0  6.5  7.0  7.5  8.0  8.5  9.0  9.5 10.0
```

või saab tema abil tekitada etteantud pikkusega vektori:

```
> seq(0,1,length=4)
[1] 0.0000000 0.3333333 0.6666667 1.0000000
```

Käsuga rep saab esimest argumenti korrata soovitud arv kordi:

```
> rep(3,10)
 [1] 3 3 3 3 3 3 3 3 3 3
> rep(c(1,7,9),2)
[1] 1 7 9 1 7 9
> rep(c("Tallinn","Tartu"),c(3,2))
[1] "Tallinn" "Tallinn" "Tallinn" "Tartu" "Tartu"
```

Ülesanded

1. Pika, 10 aastat kestnud uuringu käigus püüti lõksudega metsast kinni 123 halli karvaga hiirt, 156 täpilise karvaga hiirt ja 23 mummulise karvaga hiirt. Tekita vektor, mis sisaldaks kinnipüütud hiirte karvavärvi (iga hiire värv eraldi kirjas).

Graafikast

Andmete visualiseerimiseks ja statistikas vajaminevate jooniste tegemiseks pole arvatavasti olemas R´ist paremat vahendit. Jooniste kvaliteet vastab ka rangemaile nõuetele ja sisu poolest olulist on äärmiselt lihtne esile tõsta. Lühiülevaate R´i graafika võimalustest võib saada käsuga `demo(graphics)`, vaata ka http://www.ms.ut.ee/mart/R/Rgraafika.html

Esmalt mõned sagedamini kasutamist leidvad käsud.

`barplot` - tulpdiagrammi tegemine;
`plot` - käsk, mida võib proovida enam-vähem kõige visualiseerimiseks, olgu see siis andmevektor, regressioonanalüüsi mudel või klasteranalüüsi tulemused;
`pie` - „kakuke“;
`boxplot` - nn karp-vurrud diagramm;
`hist` - histogramm.

Näiteid nende käskude kasutamisest:

```
barplot(table(sugu))
pie(table(olu))
pie(c(7,5,10,10,20), labels=c(„Reform“,“Isamaa“,“Kesk“,
     “Res Publica“,“üksik.“))
boxplot(pikkus~sugu, names=c("Naised", "Mehed"))
hist(pikkus)
plot(pikkus)
plot(pikkus, kaal)
```

```
hist(pikkus, main="Tudengite pikkused", ylab="sagedus", col="gold")
```

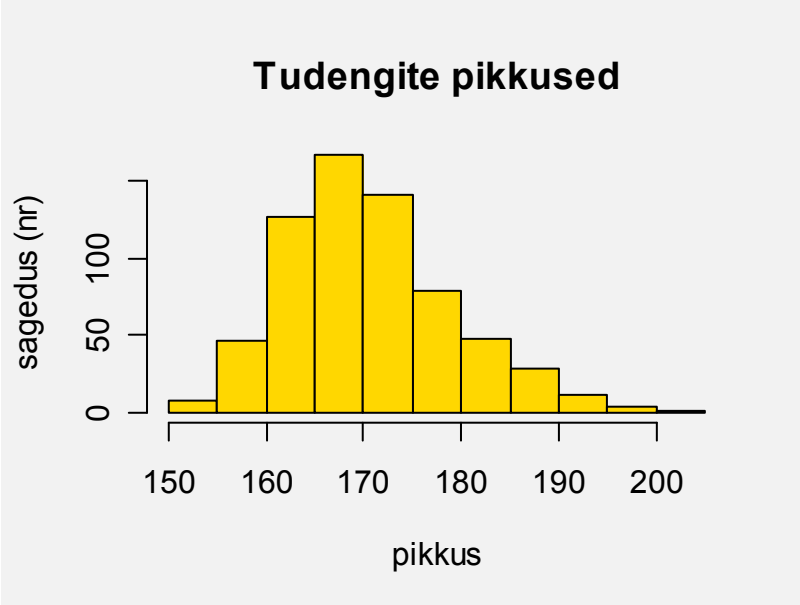

Tudengite pikkuste histogramm koos andmetega kõige paremini sobiva normaaljaotusega (normaaljaotuse tihedusfunktsiooni graafikuga):

```
hist(pikkus, main="Tudengite pikkused", ylab="sagedus",
      col="gold", freq=FALSE)
x=seq(140, 210, length=500)
lines(x, dnorm(x, mean=mean(pikkus), sd=sd(pikkus)), lwd=2)
```

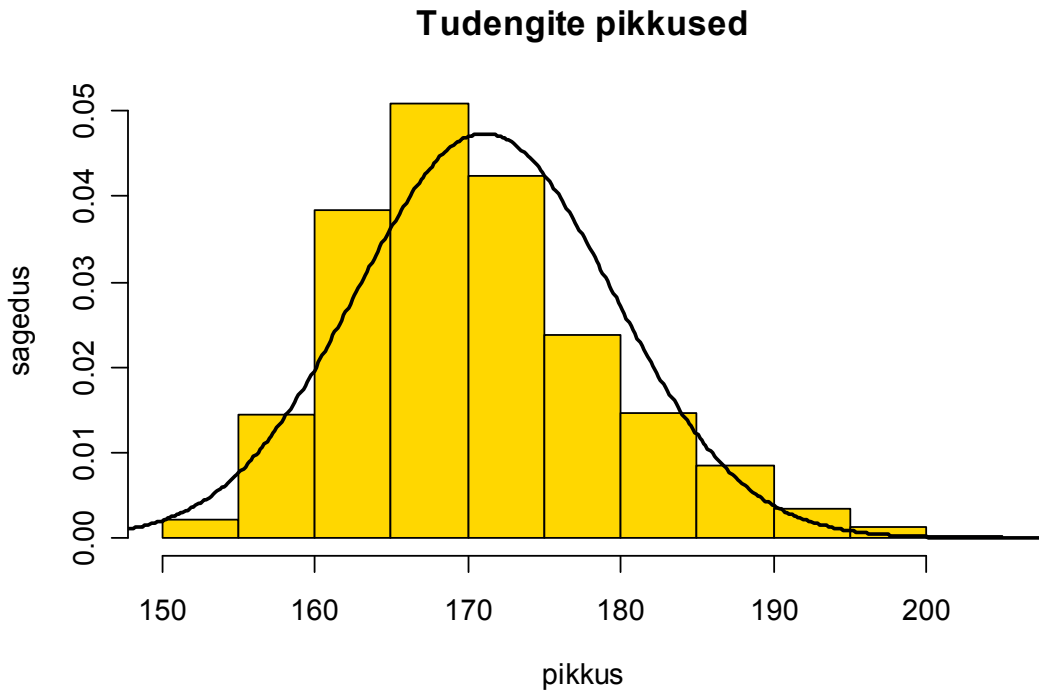

Karpdiagramm pikkusele

```
boxplot(pikkus)
```

```
boxplot(pikkus~sugu, col="skyblue1",
names=c("naised","mehed"), main="Karpdiagramm
pikkusel
```

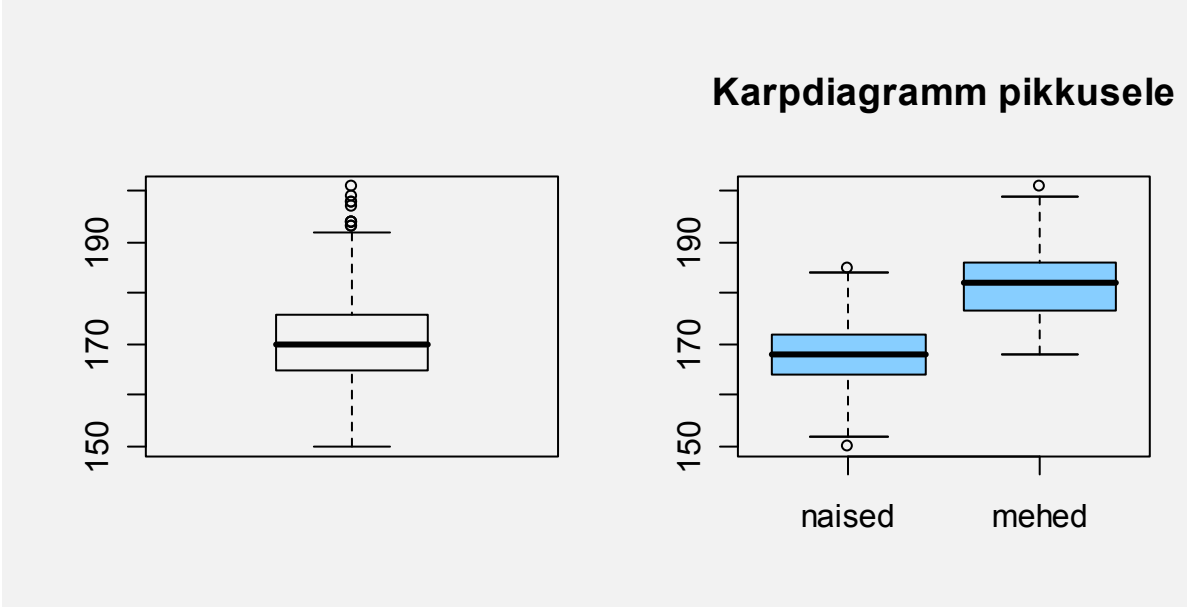

Jooniste kohandamine

Kui arvuti joonistab teile esimesel katsel just sellise joonise, nagu te soovite, siis pole teil arvatavasti soovi lugejatele midagi sisulist ja uudset öelda. Kõigil ülejäänud juhtudel läheb tarvis graafikute sättimist sobivamaks, sellisteks kust sisuline informatsioon esile tõuseks. Selleks on kasulikud mõned käsud, mis (enam-vähem) töötavad kõigi ülalloetletud graafikafunktsioonidega.

Graafikul nähtavat osa saab piiritleda käskudega *xlim* ja *ylim* (mõne mitteloetletud funktsiooni korral saab kasutada ka käsku *zlim*). Näiteks proovi, mille poolest erinevad järgmise kahe käsu tuemused:

```
plot(pikkus, kaal)
plot(pikkus, kaal, ylim=c(0,130))
```

Telgede tähistusi saab muuta käskudega *xlab* ja *ylab;* pealkirja saab lisada käsuga *main*:

```
barplot(table(olu), names.arg=c("ei joo", "alla 1",
     "1-4", "5-12", "13+"), xlab="pudelit nädalas",
     ylab="Sagedus", main="Tudengite õlletarbimine",
     col=rainbow(8))
```

Kasutatavaid värve saab sageli muuta käsuga *col*:

```
> barplot(table(sugu),col=c("orange", "skyblue"))
```

Andes käsu `colors()` näidatakse kõiki R´ile nimepidi tuttavaid värve, värve saab valida ka mõnest valmiskomplektist. Näiteks funktsioon `heat.colors(6)` tekitab 6 värvi soe-tulikuum skaalal:

```
> barplot(1:10,col=heat.colors(10))
```

Täpsemalt informatsiooni värvide kohta saab käsuga `?colors`.

Joonistades kauneid graafikuid soovitakse mõnikord suurendada telgedel kasutatavaid tekste, muuta tausta vms värve, suurendada või vähendada telgede jaoks jäetud ruumi jms. Selliste spetsiifiliste lisaparameetrite kohta, mida sageli võib lisada kõigile joonistamisega tegelevatele käskudele, saab lisainformatsiooni käsuga `?par`.

Teisi olulisi graafikaga seotud käske:

`lines`	- lisa olemasolevale pildile jooni
`points`	- lisa olemasolevale pildile punkte
`text`	- lisa pildile teksti
`legend`	- lisa pildile legend
`arrows`	- joonista kuhugi osutav nooleke
`axis`	- graafikule ebatüüpilise telje lisamiseks

Ülesanded

1. Mida teeb järgmine käsk?
boxplot(pikkus~olu, col="tan")
Kuidas toodud käsku tuleks täiendada, et telgedele tekiksid mõistlikud pealkirjad?
2. Tudengite süstoolne vererõhk on kirjas tunnuses SVR ja diastoolne vererõhk on kirjas tunnuses DVR. Joonista mõlema tunnuse jaoks histogrammid. Kas näed midagi üllatavat, ootamatut?
2. Pikkuste ja kaalude seost iseloomustava joonise saame tellida käsuga
plot(pikkus, kaal)
Lisa sellele joonisele punane nooleke, mis viitaks ühele lühikesele ja paksule tudengile.
Vihje: noole lisamiseks saab kasutada arrows-käsku.

Näide R´i graafikust:

```
> barplot(c(145,108,80,33,26,12,5),
names.arg=c("mänd","kask","kuusk","hall-lepp", "haab", "sanglepp",
"muud"), main="Eesti metsade üldtagavara \n RMK 2001. aasta
keskkonnaraporti andmetel", ylab="miljonid tihumeetrid",
col=gray(3:10/10))
```

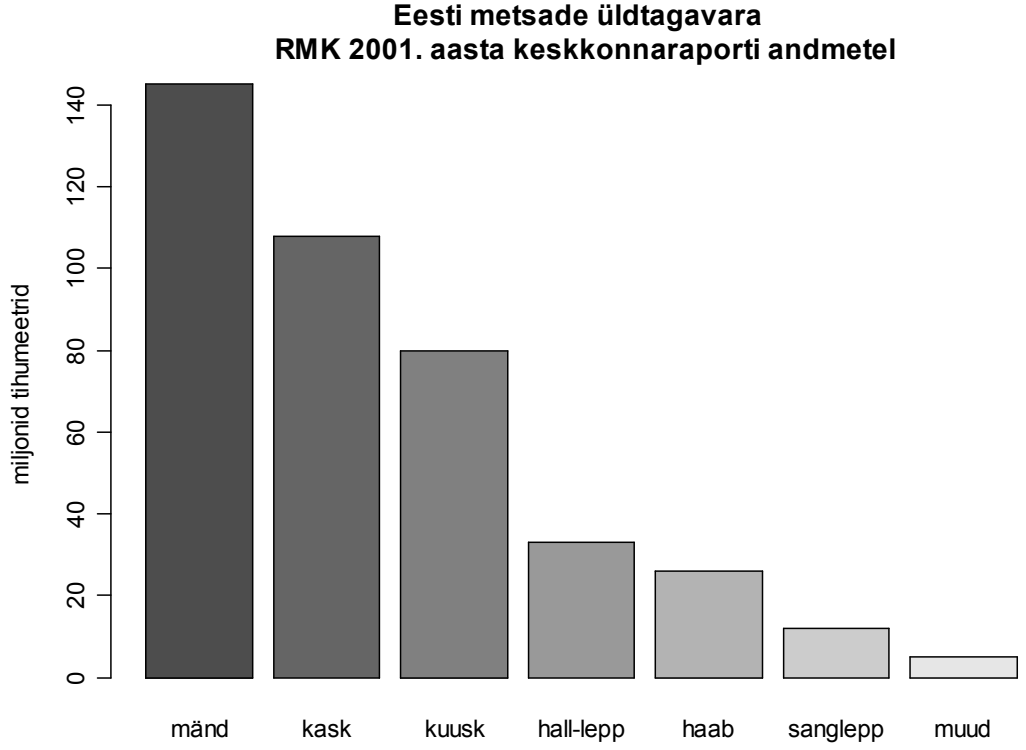

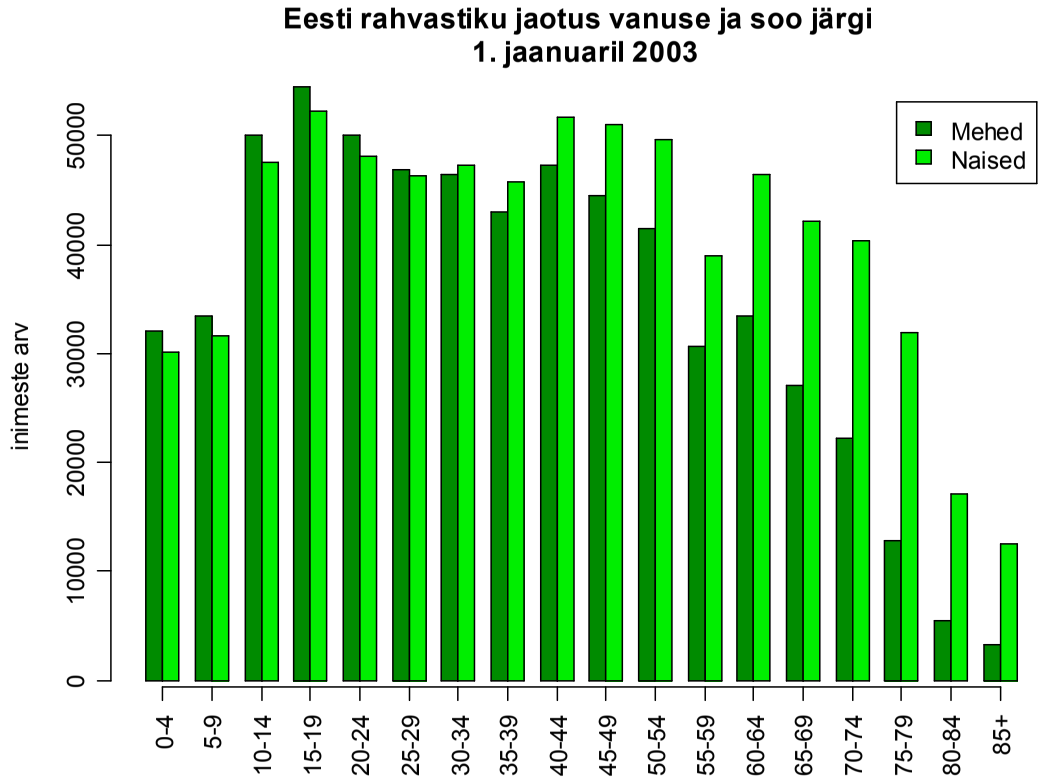
Eesti rahvastiku jaotus vanuse ja soo järgi
1. jaanuaril 2003
inimeste arv
0
10000
20000
30000
40000
50000
Mehed
Naised
0-4
5-9
10-14
15-19
20-24
25-29
30-34
35-39
40-44
45-49
50-54
55-59
60-64
65-69
70-74
75-79
80-84
85+

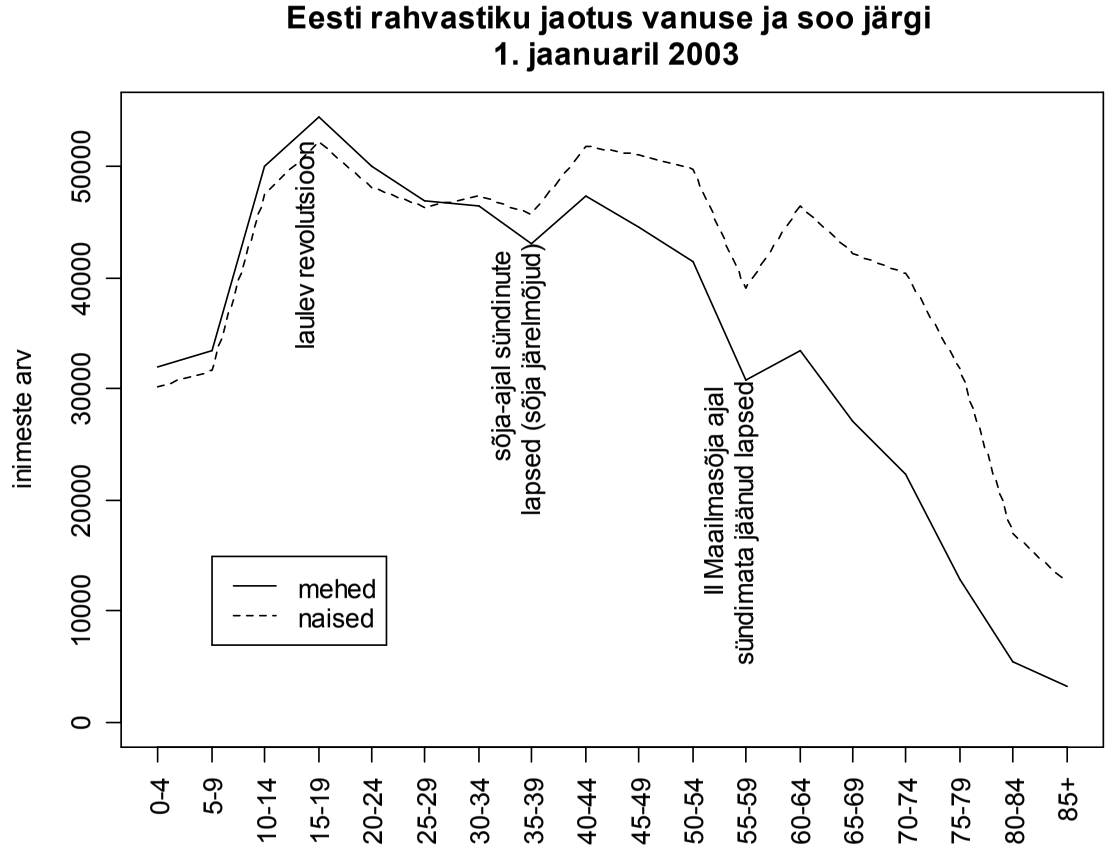
Eesti rahvastiku jaotus vanuse ja soo järgi
1. jaanuaril 2003
inimeste arv
0
10000
20000
30000
40000
50000
laulev revolutsioon
sõja-ajal sündinute
lapsed (sõja järelmõjud)
II Maailmasõja ajal
sündimata jäänud lapsed
mehed
naised
0-4
5-9
10-14
15-19
20-24
25-29
30-34
35-39
40-44
45-49
50-54
55-59
60-64
65-69
70-74
75-79
80-84
85+

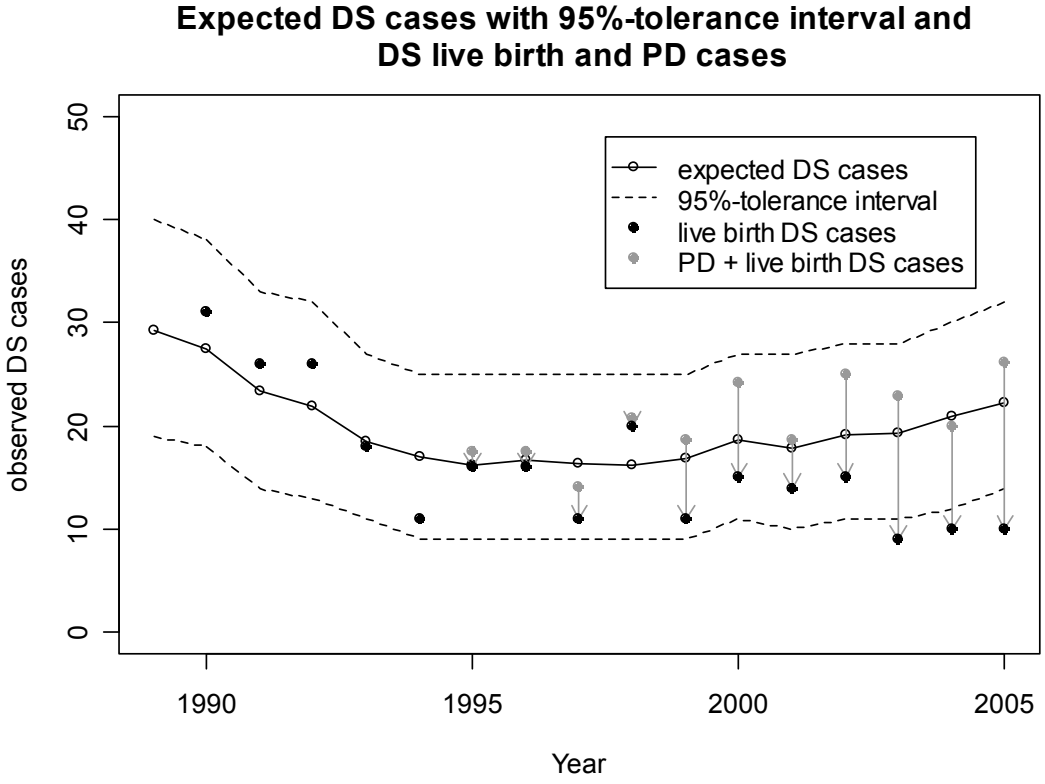
Expected DS cases with 95%-tolerance interval and
DS live birth and PD cases
expected DS cases
95%-tolerance interval
live birth DS cases
PD + live birth DS cases
observed DS cases
0
10
20
30
40
50
1990
1995
2000
2005
Year

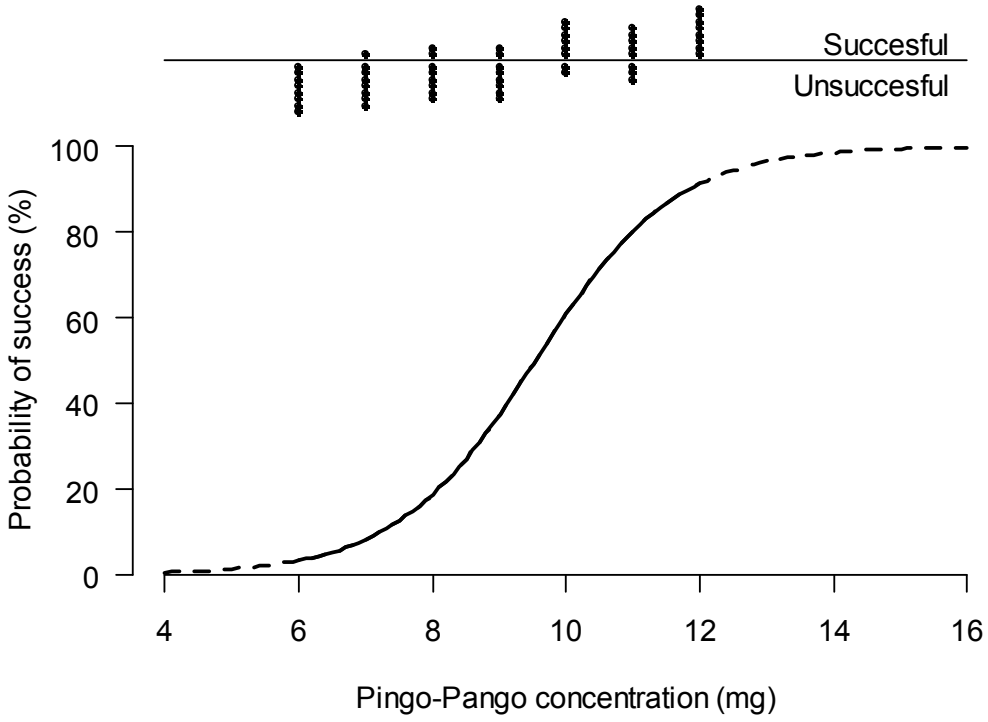
Succesful
Unsuccesful
Probability of success (%)
0
20
40
60
80
100
4
6
8
10
12
14
16
Pingo-Pango concentration (mg)