


# Rakendustarkvara: R. Sügis 2017, 5. praktikum\*

## 1 Joonised paketi ggplot2

### 1.1 Graafika R-is. ggplot2 ja graafikute grammatika

R-i üks tugevaid külgi on tema jooniste tegemise võimekus. Toome siinkohal ära paar kõige rohkem kasutatavat baaspaketi joonistamise käsku:

```
# andmed = Massachusettsi osariigi valikuuringu andmed
par(mfrow = c(1, 2), cex = 0.6) # see rida võimaldab kaks joonist kõrvuti panna
hist(andmed$AGE, xlab = "Vanus", ylab = "Isikuid", main = "")
plot(andmed$WKHP, andmed$WAGP, xlab = "Töötunde", ylab = "Aastapalk",
      col = as.numeric(andmed$SEX)+1)
legend("topleft", pch = 19, col = 2:3, legend = levels(andmed$SEX))
```



Kuigi R-i baasgraafika on peensusteni konfigureeritav ja sellega saab teha ülikeerulisi jooniseid, peab tüüpilistest andmetest kirjeldavate jooniste saamiseks tegema palju lisatööd ja -arvutusi, nagu ülalolevastki näha. Näiteks `barplot(.)` käsk soovib argumentiks saada sagedustabelit, mis tuleks siis eelnevalt `table(.)` käsu abil arvutada.

R-i kasutajate hulgas on viimastel aastatel muutunud populaarseks pakett `ggplot2`, mis võimaldab lihtsamini joonistada andmestikke kirjeldavaid jooniseid, sealjuures on tulemused visuaalselt üsna apetiitsed. Nimelt on `ggplot2` arendamisel pandud tähele statistiku Edward Tufte soovitusi värvide valikul ning eriti Leland Wilkinsoni struktureeritud käsitus andmejoonistest, nn graafikute grammatikat (*grammar of graphics*).

Üldised soovitused (Tufte):

- tindi/info suhe peab olema väike
- ei tohiks rõhutada mõnda elementi, kui see pole teistest olulisem (nt kõik värvid võiksid olla sama intensiivsusega)
- eelistada silmaga lihtsamini hinnatavaid kujundeid (nt tulba kõrgus tulpdiaagrammil vs nurgakraad ringdiaagrammil)

---

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

- eemaldada infot mitte kandvad komponendid (nt liba-3D)

Graafikute grammatika (Wilkinson) on kontseptsioon, mille kohaselt graafiku ehitamisel ei tuleks lähtuda mitte graafiku tüübist, vaid andmetest. Iga joonis koosneb järgnevatest osadest:

- andmed (inimeste palk ja sugu)
- skaalad (kas esitada palk värviskaalal või x-teljel? kas palga esitamiseks sobib nt log-skaala?)
- statistikud (kas palga puhul kujutada keskmist või summat)
- geomeetrilised kujundid (kas keskmine peaks olema märgitud tulba kõrgusega või hoopis punktikesega)
- koordinaadid (äkki sobib polaarkoordinaadistik?)
- tahud (joonis jagatud erinevateks alamjoonisteks)
- üldkujundus (font jms)

Paketis `ggplot2` on kaks graafikute tekitamise põhikäsku: `ggplot(.)` (keerukam) ja `qplot(.)` (*quick plot*, lihtsam). Käsk `qplot(.)` peaks käepärasem olema neile, kes on varem kasutanud R-i baasgraafika käske, kuid üldiselt on soovitatav ära õppida siiski `ggplot(.)` kasutamine.


Paketi `ggplot2` käskude jaoks on kõige põhjalikum dokumentatsioon internetis aadressil: <http://ggplot2.tidyverse.org/reference/>.

## 1.2 ggplot2: hajuvusdiagramm; skaalad

Paketi `ggplot2` põhimõte on joonise ülesehitamine kihthaaval: esmalt joonise põhi ja sellele lisatakse ehk liidetakse (kasutades `+` märki) kihtidena erinevad kujundused. Näiteks geomeetriliste elementide (punktid, jooned, tulbad jne) lisamiseks/muutmiseks on käsud `geom_<elementi_nimi>`.

Alustame hajuvusdiagrammist. Andmestikus `maakonnad` on info USA 5 osariigi mõnede maakondade kohta (425 maakonda). Uurime kõrgharidusega inimeste osakaalu ja keskmise sissetuleku vahelist seost. Mõistlik on seda kujutada hajuvus-diagrammina, kus iga punkt on maakond ning ühel teljel on kõrgharidusega inimeste osakaalu märkiv tunnus `bachelor` ja teisel teljel keskmise sissetuleku tunnus `per_capita_inc`:


```
mk <- read.table("http://kodu.ut.ee/~annes/Rkursus/maakonnad.txt", sep = " ")
ggplot(data = mk, mapping = aes(x = bachelor, y = per_capita_inc)) + geom_point()
#                                     joonise põhi + kujunduselement
```



Tasub tähele panna käsku `aes(.)` (nagu *aesthetics*), mida ülaloleval joonisel funktsiooni argumentidele `mapping` ette anti. Nimelt `aes(.)` funktsioon aitab siduda graafilisi elemente andmestikus olevate tunnustega.

Lisaks koordinaatidele saab üks punkt veel edasi anda infot näiteks värvi, kuju ja suurusega. Selleks seome funktsiooni `aes` abil kolm tunnust andmestikust vastavalt värvi `colour`, kuju `shape` ja suuruse `size` argumentidega:

```
ggplot(data = mk, mapping = aes(x = bachelor, y = per_capita_inc)) +  
  geom_point(aes(colour = Poverty_factor, shape = State, size = pop_estimate))
```



Igat tüüpi tunnuseid ei saa suvaliste jooniseühikutega seostada, näiteks arvulise tunnusega ei saa siduda punkti kuju (nii palju erineva kujuga punkte pole lihtsalt olemas). Samas aga saab värviga kujutada nii faktortunnust (nt osariik) kui ka arvulist tunnust (nt kõrgus merepinnast). Täpsemini on hajuvusdiagrammi ühel punktil järgmised omadused, millega saab infot edasi anda:

- `x` – (kohustuslik) asukoht x-teljel [numeric, character, logical, Factor]
- `y` – (kohustuslik) asukoht y-teljel [numeric, character, logical, Factor]
- `alpha` – läbipaistvus, väiksem väärtus tähendab suuremat läbipaistvust [numeric, character, logical, Factor]
- `colour` – värvus [numeric, character, logical, Factor]
- `fill` – sisemuse värvus (ainult mõne `shape` väärtuse korral) [numeric, character, logical, Factor]
- `shape` – punkti kuju (kuni 25 erinevat + ise määratavad sümbolid) [logical, character, Factor]
- `size` – punkti suurus [numeric, character, logical, Factor]

### 1.2.1 Ülesanded

1. Loe sisse maakondade andmestik: `mk <- read.table("http://kodu.ut.ee/~annes/Rkursus/maakonnad.txt", sep = " ", header=T)`
2. Joonista hajuvusdiagramm keskkooli lõpetanute protsendi (`high_scl`) ja ülikooli lõpetanute protsendi (`bachelor`) vahel. Kas on näha mingit seost?
3. Lisa joonisele osariigi (`State`) kohta käiv info; katseta erinevaid variante (värv, kuju jne)
4. Kujuta joonisel mingil moel ka maakonna rahvaarvu (`pop_estimate`)

## 1.3 ggplot2: tulpdiagramm; elementide asukoht

Graafiku teljed võivad olla seotud ka diskreetse tunnusega (nt `Factor`), näiteks võiksime maakondi kujutades siduda x-teljega osariigi:

```
ggplot(data = mk, aes(x = State)) + geom_bar()
```

Tekkis tulpdiagramm, kus iga tulp näitab maakondade arvu vastavas osariigis. Ent maakonnad ühe tulba sees võivad olla erinevad, näiteks vaesustaseme (`Poverty_factor`) poolest. Selleks võib iga tulba vastavate maakondade arvu järgi ära värvida. Kuna iga joonise element koosneb piirjoonest ning sisemisest osast, tuleb vastava osa värvi muutmiseks kasutada kas argumenti `colour` või `fill`:

```
ggplot(data = mk, aes(x = State)) + geom_bar(aes(fill = Poverty_factor))
```

Kui on soov esitada maakondade kaupa vaesuse määra osakaalud (mitte absoluutarvud), siis peab kasutama lisaargumenti `position = "fill"`, ühtlasi on siis mõistlik muuta y-telje nimetus:

```
ggplot(data = mk, aes(x = State)) + geom_bar(aes(fill = Poverty_factor), position = "fill") +  
  ylab("osakaal")
```

Sageli esitatakse tulpdiagrammi tulbad horisontaalselt, selle saavutamiseks tuleb käsk kirja panna sama moodi kui enne, aga lisada tuleb joonise pööramine:

```
ggplot(data = mk, aes(x = State)) + geom_bar() + coord_flip()
```


### 1.3.1 Ülesanded

1. Tee joonis iseloomustamaks sünnitamistaseme (`Birth_factor`) ja vaesuse taseme (`Poverty_factor`) vahelist seost.
2. Tee joonis, mis kirjeldaks sissetulekut (`per_capita_inc`) erinevates osariikides.
3. Tee joonis, mis kirjeldaks sissetulekut (`per_capita_inc`) erinevates osariikides, aga proovi sissetulek seostada x-teljega.

## 1.4 Jooniste tüübid


Olenevalt tunnuse tüübist sobib kasutada erinevaid graafikuid. Näiteks kui uurime tekstiliste väärtustega ja pideva arvutunnuse vahelist seost, siis sobib kasutada karpdiagrammi:

```
ggplot(data = mk, aes(x = State, y = per_capita_inc)) + geom_boxplot()
```



Tunnuse jaotuse võrdlemiseks gruppides sobib ka tihedusfunktsioon

```
ggplot(data = mk, aes(x = per_capita_inc, fill = State,)) + geom_density()
```




Väike kokkuvõtte joonise tüüpide valikust:

| Tunnus1        | Tunnus2           | Sobivad joonised          | geom_<?>  |
|----------------|-------------------|---------------------------|-----------|
| pidev/arvuline | -                 | histogramm (tulbad)       | histogram |
| pidev/arvuline | -                 | tihedus                   | density   |
| kategooriline  | -                 | tulpdiagramm (tulbad)     | bar       |
| kategooriline  | kategooriline     | tulpdiagramm (tulbad)     | bar       |
| pidev/arvuline | pidev/arvuline    | hajuvusdiagramm (punktid) | point     |
| pidev/arvuline | kategooriline     | karpdiagramm (karbid)     | boxplot   |
| pidev/arvuline | aeg vms järgnevus | joondiagramm (jooned)     | line      |


Erinevaid elemente saab joonisel ka korraga kujutada. Näiteks aegrideade puhul esitada koos mõõtmispunktid ja neid ühendav joon

```
time <- 1:12
value <- c(9, 4, 3, 5, 6, 8, 8, 15, 26, 29, 24, 23)
# data.frame käsk aitab ise käsitsi andmestikku tekitada
andmed <- data.frame(time, value)
ggplot(andmed, aes(x = time, y = value)) + geom_line() + geom_point()
```



Joondiagramm mitmes grupis:

```
d <- data.frame(grupp = rep(c("platseebo", "ravim"), each=5),
               pulss = c(130, 125, 121, 124, 125, 131, 115, 99, 89, 82),
               arstivisiit = rep(1:5, 2))
ggplot(data = d, aes(x = arstivisiit, y = pulss, colour = grupp)) +
  geom_line() + geom_point() + ylim(0, 135)
```



Mõnikord harvem muidugi võib olla soov esitada pideva ja kategoorilise tunnuse vahelise seose kirjeldamiseks mitte karpdiagramme, aga näiteks keskmisi koos usaldusvahemikega. Sellistest keerukamate võimalustest tuleb hiljem juttu.


### 1.4.1 Ülesanded

1. Joonista tunnuse `bachelor` histogramm.
2. Uuri tunnuse `high_scl` jaotust erinevates osariikides, kasutades karpdiagrammi.
3. Kasuta arstivisiitide andmestikku  
`visiidid <- read.table("http://kodu.ut.ee/~annes/Rkursus/visiidid.txt", sep = "\t", header = TRUE)`  
Tee joondiagramm vererõhunäitudele (x-teljel aeg). Värvide jooned vastavalt inimese soole.

## 1.5 Joonise jagamine tahkudeks

Sageli on mõistlik ühe suure ja kirju pildi asemel joonistada palju väikeseid sarnase sisuga pilte. Selmet erinevate osariikide maakondade vaesus- ja haridustaseme seost ühel ja samal pildil kujutada, võiks seda iga osariigi jaoks teha eraldi. Joonise tahkudeks jagamiseks saab kasutada käsku `facet_wrap`. Sellele argumendile tuleb väärtus anda nn **valemi kujul**: `ridadeks_jagav_muutuja ~ veergudeks_jagav_muutuja`. Ühe neist muutujatest võib ka ära jätta:

```
ggplot(data = mk, aes(x = bachelor, y = perc_poverty)) + geom_point() +
  facet_wrap(facets = ~State)
```



### 1.5.1 Ülesanded

1. Joonista hajuvusdiagramm keskkooli ja ülikooli lõpetanute protsendi jaoks (tunnused `high_scl` ja `bachelor`) erinevate `Birth_factor` tasemete kaupa.
2. Järjesta `Birth_factor` väärtused mõistlikumas järjekorras ja tee see joonis uuesti.
3. Lisa eelmisele joonisele ka jaotus osariikide kaupa. Kas erinevates osariikides on seosed on samad või erinevad?
4. Kasuta arstivisiitide ja inimeste andmestikke  

```
visiidid <- read.table("http://kodu.ut.ee/~annes/Rkursus/visiidid.txt", sep = "\t", header = TRUE)
```

```
inimesed <- read.table("http://kodu.ut.ee/~annes/Rkursus/isikud.txt", sep = "\t", header = TRUE)
```

 Tee nende andmete põhjal järgmine joonis:

