

Lineaarsed mudelid

4. praktikum

Paremini saab alati!

(või kas ikka saab?)

Agronoom Ahti eksperimenteeris põllul – lisa põllu kündmise ajal mullale praegu veel salastatud lisaiinet x (erinevates kogustes) ja uuris, kas aine lisamine mõjutab saagikust (tunnus y). Kuna pärisandmed on jätkuvalt veel salastatud (seniks kuni lisaiine x patenteerimisprotsess käib) peame hakkama saama ja analüüse tegema kasutades kunstlikku abivahendit ehk genereeritud andmestikku:

```
set.seed(19)
x=1:10
y=2+0.85*x+rnorm(10, sd=7)
m1=lm(y~x)
summary(m1)
```

Näeme oma suureks kurvastuseks, et olemasolevate andmete põhjal lisaiine x mõju tõestada ei õnnestu. Õnneks tuli Ahtile hea mõte enne regressioonanalüüsi tegemist vaatlusandmeid siluda. Ta asendab vaatluse y_i vaatlusega y_i^* mis on leitud järgmisel viisil:

$$y_i^* = (y_{i-1} + y_i + y_{i+1})/3$$

Antud valemi rakendamisel tekivad muidugi raskused esimese ja viimase vaatlusega (peaksime ju y_1^* leidmiseks teadma vaatlust y_0 , mida meil pole kusagilt võtta ja vaatluse y_n^* leidmiseks läheks tarvis vaatlust y_{n+1} millega on sama häda...). No tuleb siis hakkama saada ilma esimese ja viimase vaatluseta (võime nende vaatluste väärtusteks kirjutada NA ehk märkida nad puuduvateks väärtusteks).

Uuri ja proovi aru saada mida teevad järgmised käsud:

```
abi=data.frame(vaatlus=y, jargmine=c(y[-1], NA), eelmine=c(NA,y[-10]))
yuus=rowSums(abi)/3
data.frame(abi, yuus)
```

Kasutades transformeeritud tunnust `yuus` proovis Ahti uuesti hinnata regressioonmudelit:

```
m2=lm(yuus~x)
summary(m2)
```

Oma rõõmuks leidis Ahti järgmist:

- regressioonsirge tõusu hinnang oli muutunud täpsemaks (standardviga oli pisem)
- tunnuse x mõju osutus nüüd statistiliselt oluliseks (on väiksem kui 0,05)!
- Mudeli headust näitav determinatsioonikordaja R^2 on muutunud märksa suuremaks – uus mudel on võimeline kirjeldama ära hoopis suurema osa uuritava tunnuse hajuvusest!

Selgita, kuidas on see võimalik Gauss-Markovi teoreemi valguses?

- Miks Gauss-Markovi teoreem on antud juhul asjasepuutuv?
- Miks Gauss-Markovi teoreemi järgi BLUE-hinnang ei osutunud täpsemaks?

Mõtiskle nähtud tulemuste valguses järgmiste küsimuste üle:

Kumb meetod andis regressioonsirge tõusule ikkagi täpsema hinnangu?

Vaata mõlema meetodi abil hinnatud regressioonsirge tõuse.

Kõik mudeli parameetrite hinnangud (ühe pika vektorina) saad kätte käsuga:

```
coef(m1)
```

Regressioonsirge tõusu (teise parameetri) hinnangu saab välja noppida käsuga

```
coef(m1)[2]
```

Hinnangu standardvea hinnangu saad soovi korral kätte aga nii:

```
coef(summary(m1))[2,2]
```

Simuleeri 1000 eksperimentaatori tulemusi ja salvesta kõigi simuleeritud andmestike korral mõlemal viisil leitud hinnangud regressioonsirge tõusule. Lisaks salvesta ka hinnangute standardvigade hinnangud. Hinda nende 1000 eksperimendi põhjal järgmiste näitajate väärtused.

1. Kontrolli, kas mõlema mudeli poolt antavad hinnangud regressioonsirge tõusule on nihketa hinnangud. Milline on sinu otsus:

.....

2. Leia esimese mudeli korral hinnangu (regressioonsirge tõusu) dispersioon

.....

3. Leia teise mudeli korral hinnangu (regressioonsirge tõusu) dispersioon

.....

4. Leia esimese mudeli korral hinnangute dispersioonidele antud hinnangute keskmine

.....

5. Leia teise mudeli korral hinnangute dispersioonidele antud hinnangute keskmine

.....

Kumb mudelitest siis ikkagi andis täpsema hinnangu sind huvitavale parameetrile?

Jätkame tegelemist põllumajandusega. Loeme sisse järgmise pisiandmestiku:

```
andmed=read.table(url("http://www.ms.ut.ee/mart/linmud2018/saagikus.csv"),
  header=TRUE)
head(andmed)
```

Tegemist on eri sorti põlluviljade saagikusega erinevatel aastatel (saak pindalaühiku kohta).

```
m1=lm(saak~factor(sort))
summary(m1)
```

Mida näitab vabaliige, mida `factor(sort)`D järel olev parameeter?

Võrdle:

```
mean(saak[sort=="A"])
mean(saak[sort=="D"])
```

Milline sortidest annab kõige halvemini saaki?

Lisame mudelile veidi „uhkust“:

```
m2=lm(saak~factor(sort)+factor(aasta))
summary(m2)
```

Mida näitab vabaliige, mida `factor(sort)`D järel olev parameeter?

Milline sortidest annab (hinnanguliselt) kõige halvemini saaki?

Mida annavad (sisuliselt) meile järgmised käsud:

```
library(gmodels)
estimable(m2,c(1, 0,0,1, 0,0,0), conf.int=0.95)
estimable(m2,c(1, 0,0,1, 1/4,1/4,1/4))
estimable(m2,c(1, 0,0,0, 1/4,1/4,1/4))
```

Millise `estimable`-käsu abil saaksime mudelit `m2` kasutades kätte sellesama sort-A saagikuste keskmise mida näeme kas `mean` käsu või `t.test`- käsu abil:

```
mean(saak[sort=="A"])
t.test(saak[sort=="A"])
```

Põllumees soovib võrrelda sorte A ja D. Kumba neist sortidest oleks targem kasvatada ja kui palju võiks ta saagikuses võita? Millisel viisil peaksime soovitud võrdlust läbi viima? Leia põllumehe jaoks kõige mõistlikum võrdlus kasutades `estimable`-käsku.

```
estimable(<mudel>, c(.....,.....,.....,.....,.....,.....,.....))
```