

Biomeetria

6. praktikum

Hii-ruut test. Statistiline seos

Hii-ruut test hüpoteeside kontrollimiseks jaotuse kohta.


Juhul, kui meid huvitav teoria võimaldas leida uuritava tunnuse vääruste esinemistõenäosuseid, siis saab selle teoria paikapidavust kontrollida hii-ruut testi abil. Hii-ruut testi saab R-is teha kasutades käsku `chisq.test`.

Näide

Oletame, et soovime kontrollida Mendeli seaduste kehtivust. Heterosügootide ristamisel saadi järgmised tulemused:


genotüüp	valim (n_i)	väärtuse ennustatud esinemistõenäosus (Mendeli seadus)
AA	– 20 järglast	0,25
Aa	– 32 järglast	0,5
aa	– 18 järglast	0,25

Kas Mendeli seadused kehtivad?



Järeldus: Meie katsetulemused on kooskõlas Mendeli seadustega – nad ei lükka nullhüpoteesi ümber.

Märkus: juhul kui tõenäosuste arvutamisel on kasutatud valimit (vaata loengumaterialist Hardy-Weinbergi tasakaalu kontrollimise näidet), siis R-i (ja ka teiste statistikapakettide) automaatika seda ei tuvasta ning kasutatakse valet vabadusastmete arvu. Sellisel juhul ei saa arvuti poolt vaikimisi esitatud tulemust usaldada – see on lihtsalt vale. Õnneks saab tehtud tööd siiski kasutada – olulisustõenäosust saab leida ka siis, kui oleme ise käsitsi õige vabadusastmete arvu leidnud (hiir-statistiku arvutamise võib ikka arvutile jäätta). „Käsitsi“ arvutatud vabadusastmete arvu saab kasutada olulisustõenäosuse arvutamisel nii:



Ülesanne

Soovime kontrollida, kas kõik uurimisalused aastad (2002-2006) olid kotkaliik-X-le pesitsemiseks samasobivad või oli mõni aasta silmnähtavalt ebasoivam. Igal aastal jälgiti 10-t kotkapesa ja loeti üle täiskasvanuks kasvatatud kotkalaste hulk. Saadi järgmised andmed:

Aasta	suureks sirgunud kotkaid
2002	5
2003	12
2004	8
2005	8
2006	10

Kontrolli hii-ruut testi abil, kas pesitsemisaastad olid kotkastele võrdväärseid head? Vihje: kui oleks võrdseid head, siis peaks meie andmestikku sattunud kotkapoeg olema pärit aastast 2002 samasuure tõenäosusega kui aastast 2006.

Kommenteeri testitulemust, arutle, mis võib testitulemust mõjutada (näiteks: kui kontrolliti kogu aeg samu pesi, siis võisid linnud igal aastal järjest vanemaks jäädva. Vanade lindude pesitsusedukus ei peagi olema samasugune kui noortel. Tulnuks ehk igal aastal uued pesasid otsida)?

Ülesanne

Soovitakse teada, kas linna sattuvad suured metsloomad ehk sellepärist, et neid metsas segatakse. Kui see nii on, siis peaks linna sattuma loomi rohkem just nädalavahetustel, kui metsas palju huvilisi käib. Otsustati kontrollida, kas metsloom sattub linna igal nädalapäeval sama tõenäosusega (nullhüpotees – loomade linnasattumine ei sõltu nädalapäevast – loomadel pole ju aimugi 7-päevastest nädalast) või siiski sõltub (kui sõltub, viitab see inimese „süüle“). Koguti kokku 5 aasta jooksul linnadesse/asulatesse sattunud metsloomade andmed. Nädalapäeviti jagunesid inimasulatesse sattumised järgmiselt:

Nädalapäev	E	T	K	N	R	L	P
Metsloomi	18	12	8	6	12	14	22

Kontrolli hii-ruut testi abil, kas on võimalik, et looma linna sattumine ei sõltu nädalapäevast?

Seosed tunnuste vahel

Käesolevas osas kasutame taas tudengite andmestikku. Alustuseks loemegi andmestiku sisse:

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

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

Tahame teada, kas tunnuste *sugu* ja *sport* vahel eksisteerib seos (kas naised on sportlikumad kui mehed? või pole? või ... ?), ja kui eksisteerib, siis milline see on.

Sportimisküsimuse kodeering on järgmine:

Kui tihti tegelete sportimisega?

- 1 – mitte kunagi
- 2 – 1-2 korda nädalas
- 3 – 3-4 korda nädalas
- 4 – üle 5 korra nädalas

Alustame sagedustabelist ja tema visualiseerimisest:

```
> table(sugu, sport)
      sport
sugu   1    2    3    4    5
  1 103 313  80  13   2
  2  21   69  38  19   2
```

Selle põhjal saab koheselt öelda vaid seda, et poisse satub arsiteaduskonda harvem kui tüdrukuid.
Hindame tunnuse *sport* jaotuse tüdrukute ja poiste jaoks eraldi:

```
> prop.table(table(sugu, sport),1)
      sport
sugu          1            2            3            4            5
  1 0.201565558 0.612524462 0.156555773 0.025440313 0.003913894
  2 0.140939597 0.463087248 0.255033557 0.127516779 0.013422819
```

Näeme, et naistudengid (*sugu==1*) spordivad vähem: 20% küsitletud naistudengitest ei spordi kunagi, samas kui nii vähe sporti teeved vaid 14% küsitletud meestudengitest jne.

Võime vaadata ka teistpidi – kui palju on mittesportivate tudengite seas naisi, kui palju rohkelt sportivate tudengite seas jne:

```
> prop.table(table(sugu, sport),2)
      sport
sugu          1            2            3            4            5
  1 0.8306452 0.8193717 0.6779661 0.4062500 0.5000000
  2 0.1693548 0.1806283 0.3220339 0.5937500 0.5000000
```

Näeme, et kui mittesportivatest tudengitest on 83% naised, siis 3-4 korda nädalas sportivatest tudengitest on naistudengeid kõigest 59%.

Esitame saadud tulemuse ka graafiliselt. Selleks on paar erinevat võimalust. Milline neist meeldib Sulle? Kas saad kõigi graafikute korral aru, mida seal kujutatud on?

```
barplot(prop.table(table(sugu, sport),2)*100,
       col=c("orange","skyblue"),
       ylab="%", main="Seos sportimise ja soo vahel",
       legend=c("naised", "mehed"), xlim=c(0,7.5))
```

Jätame legendi jaoks veidi ruumi

```
barplot(prop.table(table(sport, sugu),2)*100, col=terrain.colors(5),
        legend= c("ei spordi", "1-2", "3-4", "5 ja enam"),
        names.arg= c("naised","mehed"),
        xlim=c(0,3.5), ylab="%", main="Seos sportimise ja soo vahel")
```

Kas seos eksisteerib tegelikult või mitte? Valimi juhuslikkuse töttu võime ekslikult arvata, et eri soost tudengite spordivaimustus on erinev. Seda, kas seos ikka tegelikul ka eksisteerib (ka siis alles jäab, kui me lõpmatlut palju tudengeid uuriksime) saab kontrollida hii-ruut testi abil. Hii-ruut testi kasutamine kahe tunnuse sõltumatuse kontrolliks näeb antud juhul välja järgmine:

```
> chisq.test(table(sugu, sport) )
```

vabadusastmete arv

Pearson's Chi-squared test

```
data: table(sugu, sport)
X-squared = 39.4783, df = 4, p-value = 5.549e-08
```

olulisustõenäosus

Warning message:
Chi-squared approximation may be incorrect in: chisq.test(table(sugu, sport))

Hii-ruut teststatistiku väärus

Hoiatus – ootuspärased arvud on liiga väiksed!

Vaatame, millepärasest anti hoiatus – trükime välja ootused:

```
> chisq.test(table(sugu, sport))$expected
      sport
sugu      1      2      3      4      5
  1 96.00606 295.7606 91.36061 24.775758 3.0969697
  2 27.99394 86.2394 26.63939 7.224242 0.9030303
```

Näeme, et vastusevarianti 5 on valitud liiga harva. Muuseas, milline on vastusevariant 5? Miks sellised vastused üldse on andmestikku tekkinud? Kas me saame seda millegiga kokku panna?

Kaks võimalust – vali neist sinu meelest sobivaim!:

Variant1 – loeme vastusevariandid „5“ lihtsalt vastusevariantideks „4“
`sport2=sport
sport2[sport2==5]=4`

Variant2 – loeme vastusevariandid „5“ puuduvateks vastusteks (ehk viskame analüüsist välja)
`sport2=sport
sport2[sport2==5]=NA`

Kumb lähenemine tundub sulle õigem? Miks?

Peale tunnuse ümberkodeerimist teeme uuesti hii-ruut testi:

```
> chisq.test(table(sugu, sport2))  
Pearson's Chi-squared test  
  
data: table(sugu, sport2)  
X-squared = 37.9465, df = 3, p-value = 2.901e-08
```

Näeme, et hoiatust enam ei anta. Tunnuste sugu ja sport vahel eksisteerib töepooltest seos – naised teeavad vähem sporti.


Märkus: Alternatiivina võib lasta R-l arvutada olulisustõenäosuse nn. täpsel meetodil – ilma hii-ruut jaotust kasutamata:

```
chisq.test(table(sugu, sport), simulate.p.value=TRUE, B=100000)
```

Sellisel viisil tehtud hii-ruut testi puhul ei pea kõik ootuspärased sagedused olema 5 või enam (aga soovitavalt peaks siiski paljud seda olema).

Sellest, mida see seos ikka tähendab, võid proovida aru saada ka järgmise graafiku – assocplot-funktsiooni poolt joonistatava graafiku – abil.

```
assocplot(table(sugu, sport2))
```



Ülesanne:

Vaata tunnuseid *olu* ja *suitsetamine*. Kas nende tunnuste vahel eksisteerib seos? Kui jah, siis milline see on – kirjelda sõnades!

Tunnuste olu ja suitsetamine kodeeringud:

Suitsetamine: Milline järgnevatest variantidest kirjeldab kõige paremini Teie praegust suitsetamist?

- 1 – ei ole kunagi suitsetanud
- 2 – pean vahet või olen suitsetamisest loobunud
- 3 – suitsetan harvemini kui üks kord nädalas
- 4 – suitsetan mitmeid kordi nädalas, kuid mitte iga päev
- 5 – suitsetan kõige rohkem 9 sigaretti/sigareid/piibutubakat päevas
- 6 – suitsetan päevas 10-19 sigaretti/sigareid/piibutubakat
- 7 – suitsetan päevas vähemalt 20 sigaretti (või sama palju sigareid või piibutubakat)

Ölu: Kui suurel määral olete tarbinud ölu (keskmiselt) viimase aasta jooksul?

- 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