

Sensorrettleiing eksamen ECON2130

Vår 2024

Oppgave 1

a)

$$P(5 \text{ spar}) = \frac{\binom{13}{5}}{\binom{52}{5}} \approx 0.0005$$

I R:

I oppgave a) til c) brukar vi framgangsmåten: 1. trekk 5 kort mage gonger, 2. finn kor stor del av gongane vi får 'suksess'. Det viktigaste er at ein klarer å implementere ein algoritme som simulerer sannsynet, men for full uttelling bør det vere noko grad av presisjon. Altså kan ikkje talet trekk vere veldig lågt. Vi definerer ein kortstokk:

```
kortstokk <- c(rep(1, 13), rep(2, 13), rep(3, 13), rep(4, 13))
```

Vi trekker fem kort 10^5 gonger og finn andelen gonger alle fem korta er lik spar:

```
b <- replicate(1e5, sum(sample(kortstokk, 5)) == 20)
mean(b)
```

b)

$$P(5 \text{ like}) = 4 * \frac{\binom{13}{5}}{\binom{52}{5}} \approx 0.0020$$

I R:

Vi trekker fem kort 10^5 gonger og finn andelen gonger alle fem korta er like:

```
c <- replicate(1e5, length(unique(sample(kortstokk, 5))) == 1)
mean(c)
```

c)

$$P(3 \text{ spar og 2 ruter}) = \frac{\binom{13}{3} \binom{13}{2}}{\binom{52}{5}} \approx 0.0086$$

I R:

Vi definerer ein funksjon som trekk 5 kort og gir verdien 1 om vi trekk 3 spar og 2 ruter:

```
d_funksjon <- function(){
trekk <- sample(kortstokk, 5)
suksess <- length(trekk[trekk == 4]) == 3 & length(trekk[trekk == 3]) == 2
```

```
return(suksess)
}
```

Vi trekker fem kort 10^5 ganger og finn andelen ganger vi har 3 spar og 2 ruter:

```
d <- replicate(1e5, d_funksjon())
mean(d)
```

Om du gjer oppgåve 1 med simulering vil alle ekvivalente metodar som gjev omtrent same svar gi full uttelling.

Oppgave 2

- a) X er binomisk fordelt. X er summen av n uavhengige Bernoulli-forsøk med konstant sannsyn p .
- b) Sidan X er binomisk fordelt er $EX = np$. Vi brukar reknereglar for forventning og set inn for EX :

$$E[\pi] = E[bX - kn^2] = bE[X] - kn^2 = bpn - kn^2$$

Sidan $E[\pi]$ er ein konkav funksjon av n , finn vi maksimum ved å derivere og sette lim 0:

$$bp - 2kn^* = 0 \implies n^* = p * \frac{b}{2k}$$

c)

$$E[\hat{n}^*] = E\left[\frac{X}{n} * \frac{b}{2k}\right] = \frac{b}{2kn} * E[X] = \frac{b}{2kn} * np = p * \frac{b}{2k} = n^*$$

\hat{n}^* er forventningsrett.

Sidan X er binomisk fordelt er $Var(X) = np(1-p)$. Vi brukar reknereglar for varians og set inn for $Var(X)$:

$$Var[\hat{n}^*] = Var\left[\frac{X}{n} * \frac{b}{2k}\right] = \left(\frac{b}{2kn}\right)^2 * Var[X] = \left(\frac{b}{2kn}\right)^2 * np(1-p) = \left(\frac{b}{2k}\right)^2 * \frac{p(1-p)}{n}$$

Estimatet er lik:

$$\hat{n}^* = \frac{60}{500} \frac{1500}{2 * 0.1} = 900$$

- d) Sidan \hat{n}^* er gjennomsnittet av n stokastiske variablar ganga med ein konstant veit vi gjennom sentralgrenseteoremet at \hat{n}^* blir tilnærma normalfordelt når n blir stor.

For våre observasjonar er

$$E(\hat{n}^*) = 900$$

Sidan vi ikkje veit den faktiske verdien av p må vi bytte ut p i variansen med estimatet $\hat{p} = X/n = 0.12$. Variansen blir då:

$$Var(\hat{n}^*) = \left(\frac{1500}{2 * 0.1}\right)^2 * \frac{0.12(1-0.12)}{500} = 11880$$

og

$$SE(\hat{n}^*) = \sqrt{Var(\hat{n}^*)} = 109$$

Vi brukar formelen for konfidensintervall:

$$KI = [\hat{n}^* - z_{\alpha/2}SE(\hat{n}^*), \hat{n}^* + z_{\alpha/2}SE(\hat{n}^*)]$$

Vi finn z_{α} ved å slå opp i statistikktabell eller ved å bruke `qnorm(0.995)` og finn ein z-verdi lik 2.58. Ved å sette inn verdiane i formelen for konfidensintervall får vi:

$$KI = [900 - 2.57 * 109, 900 + 2.57 * 109]$$

$$KI = [620, 1180]$$

- e) Vi vil teste om n^* er mindre eller lik 1000, eller om n^* er større enn 1000. Naturlege hypoteser er derfor:

$$H_0 : n^* \geq 1000, H_1 : n^* < 1000$$

Om du i staden set opp ein tosidig hypotesetest vil du få noko, men ikkje full uttelling.

Vi brukar formelen for standardfeil frå oppgåve c) for å finne standardfeilen under nullhypotesa:

$$SE(\hat{n}_0^*) = \sqrt{\left(\frac{1500}{2 * 0.1}\right)^2 * \frac{0.13(1 - 0.13)}{500}} = 113$$

Vi konstruerer teststatistikken:

$$z = \frac{900 - n_0^*}{SE(\hat{n}_0^*)} = \frac{900 - 1000}{113} = -0.88$$

Her skal du helst velje signifikansnivå på førehand. Det høgste vanlege konfidensnivået er 10%, og då er kritisk z-verdi lik -1.28 , og vi forkastar ikkje nullhypotesa. Vi vil då heller ikkje forkaste nullhypotesa for lågare signifikansnivå.

- f) For å finne p-verdien brukar vi formelen for p-verdiar ved ei ein-sidig hypotese:

$$pverdi = \Phi(z) = \Phi(-0.88) = 0.17$$

P-verdien er dermed lik 0.17. Vi finn verdien av $\Phi(z)$ ved å enten slå opp i statistikktabell eller ved å bruke 'pnorm(z)' i R.

Oppgåve 3

a) Vi brukar føresetnadane for at ein variabel skal vere Poisson-fordelt på vårt eksempel:

- Kor mange fisk du får innan eit gitt tidsintervall er uavhengig av kor mange fisk du får i andre intervall
- Det forventa talet fisk du får på kvar fisketur på fire timar er lik λ
- Du kan ikkje få to fisk nøyaktig samtidig

For full uttelling må alle dei tre føresetnadane vere nemnd.

b) $\hat{\lambda}$ er gjennomsnittet av $n = 50$ stokastiske variabalar og vi kan bruke sentralgrenseteoremet som gir at $\hat{\lambda}$ er normalfordelt med $E(\hat{\lambda})$ og $Var(\hat{\lambda})$. Sidan $\hat{\lambda}$ er gjennomsnittet av $n = 50$ uavhengige variablar med forventning $\lambda = 4$ og varians $\lambda = 4$ er $E(\hat{\lambda}) = \lambda = 4$ og $Var(\hat{\lambda}) = \lambda/n = 4/50 = 0.08$.

Vi kan derfor bruke tilnærminga $\hat{\lambda} \sim \mathcal{N}(4, 0.08)$

c)

$$P(\hat{\lambda} \leq 3.5) = P\left(\frac{\hat{\lambda} - E(\hat{\lambda})}{\sqrt{Var(\hat{\lambda})}} \leq \frac{3.5 - 4}{\sqrt{0.08}}\right) = P(Z \leq -1.77) = 1 - P(Z \leq 1.77)$$

Vi slår opp i statistikktabell eller brukar 'pnorm(1.76)' i R og finn at:

$$P(\hat{\lambda} \leq 3.5) = 1 - 0.96 = 0.04$$

Ein kan også gjere heile utrekninga i R ved å bruke 'pnorm(3.5,4,sqrt(0.08))'.

For å finne det eksakte sannsynet utnyttar vi at $X \sim Poisson(4 * 50)$. Vi finn derfor sannsynet:

$$P(\hat{\lambda} \leq 3.5) = P(X/n \leq 3.5) = P(X \leq 3.5 * n) = P(X \leq 175)$$

Dette sannsynet finn vi i R ved å bruke 'ppois(175,200)' og vi får:

$$P(\hat{\lambda} \leq 3.5) = 0.04$$

Vi ser at normalfordelinga er ei god tilnærming då resultatane er identiske med to desimalar.

- d) Ein type I-feil er å forkaste ei riktig nullhypotese. Signifikansnivået α er sannsynet for å gjere ein type I-feil ved ein hypotesetest.
- e) Ein type II-feil er å ikkje forkaste ei gal nullhypotese. Viss ein reduserer signifikansnivået α aukar ein samtidig krava for å forkaste nullhypotesa, og ein aukar dermed sannsynet for type II-feil.
- f) Det er fleire måtar å simulere teststyrken i R. Nedanfor er to av metodane som vart gjennomgått på forelesing vist. Begge metodane gir svar på omtrent 0.18. Dette vil sei at sannsynet for å gjere ein type II-feil ved denne hypotesetesten er omtrent 0.18. Alle metodar som gjer det same som det er spurt om i oppgåva gir full uttelling. Viss du i staden for å trekke verdiar av X trekk verdiar

av normalfordelt $\hat{\lambda}$, vil du får noko, men ikkje full uttelling.

Med for-loop:

```
forkast <- vector()
for(i in 1 : 1000){
  x <- rpois(50, 4)
  test <- t.test(x, mu = 3.5)
  forkast[i] <- test$p.value <= 0.01
}
mean(forkast)
```

Med ein kombinasjon av 'function' og 'replicate':

```
forkast <- function(){
  x <- rpois(50, 4)
  test <- t.test(x, mu = 3.5)
  return(test$p.value <= 0.01)
}
sim <- replicate(1000, forkast())
mean(sim)
```