



Løsningsforslag

Bioberegninger, ST1301
Mandag 21. mai, 2007

Oppgave 1

a) > x <- c(180,185,190,165,160,155)
> y <- c(1,1,2,2,2,3)
> x[x<mean(x)]
[1] 165 160 155
> mean(x[y==2])
[1] 171.6667
> length(y==2)
[1] 6
> length(x[y==2])
[1] 3

Merk at den logiske operatoren == virker elementvis på vektoren y slik at uttrykket y==2 blir en (logisk) vektor med samme lengde som y, altså 6.

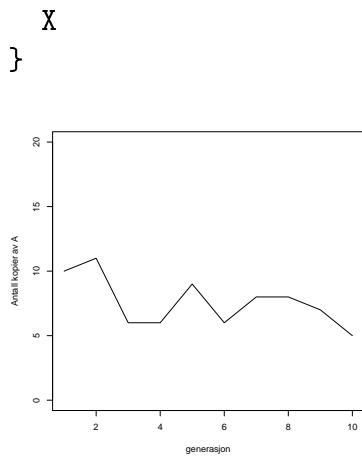
b) > funk <- function(x) {
+ n <- length(x)
+ teller <- 0
+ for (i in 2:(n-1)) {
+ if (x[i]==x[i+1] & x[i]==x[i-1]) {
+ teller <- teller + 1
+ }
+ }
+ teller
+ }
> funk(c(0.5,0.5,1,1,1,2,2,1,2,0,0,0,1,1,0,0))
[1] 2
> funk(c(0.5,0.5,1,1,1,2,2,1,2,0,0,0,0,1,1,0,0))
[1] 3

Oppgave 2

- a) Null-hypotesen vi har testet er at korrelasjonen mellom variablene alder og vekt i populasjonen er null. Siden p -verdien over er større enn $\alpha = 0.05$ kan vi ikke forkaste null-hypotesen. Det betyr at null-hypotesen kan være riktig men manglende forkastning kan også skyldes lav teststyrke (type II feil).
- b) Korrelasjons-testen forutsetter normalfordelte data. Her ser alder ut til å ha en skjev fordeling slik at normalfordelingsantakelsen ikke er oppfylt.
- c) En mye brukt fordeling for å modellere levetider er eksponensialfordelingen. Den ser også ut til å passe godt med de observerte dataene i dette tilfelle.
- d)
- ```
prob.type.I.feil : flyttall, flyttall, flyttall, flyttall, heltall, heltall
-> flyttall
##
Hensikt: Estimere sannsynligheten for type I feil i korrelasjonstest
når den ene variablen er eksponensielt (og ikke normal-) fordelt, gitt
utvalgsstørrelse n, parameterverdier, og signifikansnivå alpha.
##
prob.type.I.feil <- function(lambda,mu,sigma,alpha,n,nsim=1000) {
 teller <- 0
 t.kritisk <- qt(df=n-2,p=alpha/2,lower.tail=FALSE)
 for (i in 1:nsim) {
 x <- rnorm(n,mu,sigma)
 y <- rexp(n,lambda)
 t.sim <- cor.test(x,y)$statistic
 if ((t.sim>t.kritisk)|(t.sim< -t.kritisk))
 teller <- teller + 1
 }
 teller/nsim
}
```

## Oppgave 3

- a)
- ```
drift.sim <- function(X1,N,n) {
  X <- rep(NA,n)
  X[1] <- X1
  for (t in 2:n)
    X[t] <- rbinom(n=1,prob=X[t-1]/(2*N),size=2*N)
```



- b) Et heterozygot individ kan dannes på to måter, enten ved at genvarianten A arves fra mor eller fra far. Hver av disse hendelsene inntreffer med sannsynlighet $p_t(1 - p_t)$ slik at den totale sannsynligheten for at et individ er heterozygot (og frekvensen av heterozygoter i populasjonen) blir $2p_t(1 - p_t)$.

c)

```
forventet.heterozygotfrekvens <- function(N,X1,n,nsim=1000) {
  H <- rep(NA,nsim)
  for (i in 1:nsim) {
    p <- (drift.sim(X1,N,n)[n])/(2*N) # frekvensen i siste generasjon
    H[i] <- 2*p*(1-p) # tilsvarende realisasjon av heterozygotfrekvensen
  }
  mean(H)
}
```

- d) Vi har at heterozygotfrekvensen, funksjonen $H_t = 2p_t(1 - p_t)$ av genfrekvensen p_t , har sitt maksimum $H_t = 1/2$ i $p_t = 1/2$. Så snart vi får genetisk drift vekk fra $p_t = 1/2$ må altså H_t avta. Dermed må også $E(H_t) < H_1$.

Et litt mer stringent bevis: Vi har at $H_t < 1/2$ for alle $p_t \neq 1/2$. Fra definisjon av

forventningsverdi får vi at

$$\begin{aligned}
 EH_t &= \sum_h hP(H_t = h) \\
 &= \sum_{h \neq 1/2} hP(H_t = h) + 1/2P(H_t = 1/2) \\
 &< \sum_{h \neq 1/2} 1/2P(H_t = h) + 1/2P(H_t = 1/2) \\
 &= 1/2 = H_1,
 \end{aligned} \tag{1}$$

når $p_1 = 1/2$.

- e) Genfrekvensen etter n generasjoner er en stokastisk variabel med en viss forventning (oppgett å være lik p_1 i oppgaven) og varians. Heterozygotfrekvensen er en funksjon av denne. Vanlige regneregler fra sannsynlighetsteorien gir at

$$\begin{aligned}
 EH_t &= E2p_t(1 - p_t) \\
 &= 2Ep_t - 2E(p_t^2) \\
 &= 2Ep_t - 2[\text{Var } p_t + (Ep_t)^2] \\
 &= 2p_1 - 2[\text{Var } p_t + (p_1)^2] \\
 &= 2p_1(1 - p_1) - 2 \text{Var } p_t \\
 &= H_1 - 2 \text{Var } p_t \\
 &< H_1
 \end{aligned} \tag{2}$$

siden $\text{Var } p_t > 0$ (p_t er en stokastisk variabel med positiv varians). Altså vil forventet heterozygotfrekvens alltid avta med tiden t .