

## Plan

Kap. 9 Estimering: Mandag 7. mars og torsdag 8.mars.

Kap. 10 Hypotesetesting: Mandag 14., tirsdag 15. og **onsdag 16. 12.15-14 i R8.**

Kap. 11 Lineær regresjon (++) ??? **Onsdag 30 mars 12.15-14 i R8 ???**, 4.april, 5.april, 11.april, 12.april

Oppsummering og eksamsoppgåverekning: 26. og 27. mai (10-12).

Referansegruppemøte: Onsdag 9. mai 13.15-14. Gje tilbakemelding!

# Typiske spørsmål kap. 9 og kap 10.

- Kva er gjennomsnittshøgda for kvinnelege NTNU-studentar. **Estimering**
- Er eg høgare enn gjennomsnittleg kvinnelege NTNU-studentar. **Hypotesetest**
- Kva er forskjellen i kvalitet på laks for lagringsmetode 1 og lagringsmetode 2. **Estimering**
- Er kvaliteten på laks ved lagringsmetode 2 betre enn ved lagringsmetode 1. **Hypotesetest**

- Har data  $x_1, x_2, \dots, x_n$
- Antar fordeling frå kjennskap til fenomenet;  $x_i \sim f(x; \theta)$ .
- *Estimerer/ berekner*  $\theta$  frå data v.h.a. ein estimator  $\hat{\theta}$ .
  - Kva er ein god estimator (i dag)
  - Korleis finne ein estimator (i dag)
  - Korleis kvantifisere usikkerheita i estimat (i morgen)

Du har fått sommarjobb på vindusfabrikken. Dei tar i bruk ny produksjonsteknikk, og ønsker å finne defektsannsynet  $p$ .

- $m_1 = 40$  vindu produsert i første skift
- $m_2 = 60$  vindu i andre skift.
- $u = 5$  defekte i første skift.
- $v = 15$  defekte i andre skift.

Foreslå minst to måtar å estimere  $p$  på.

Kva sannsynsfordeling har U og V?

- La  $X_\nu = 0$  dersom vindu nr  $\nu$  er ikke-defekt, og  $X_\nu = 1$  dersom defekt.  $\nu = 1, 2, \dots, m_1 + m_2$
- $P(X_\nu = x_\nu) = p^{x_\nu} (1 - p)^{1-x_\nu}$ ; sannsynsfordeling
- $U = \sum_{\nu=1}^{m_1} X_\nu$ ; antall defekte i første skift.
- $V = \sum_{\nu=m_1+1}^{m_1+m_2} X_\nu$ ; antall defekte i andre skift.

Foreslå minst to *estimatorar* for  $p$

## Bernoulli prosess

- ①  $n$  uavhengige forsøk
- ② Kvart forsøk resulterer i suksess,  $I_i = 1$  eller ikke-suksess  $I_i = 0$ .
- ③ Suksess-sannsynet  $p = P(I_i = 1)$  er konstant.

## Binomisk fordeling

Ser på antall suksess i ein Bernoulli prosess,  $X = \sum_{i=1}^n I_i$ .  $X$  er då binomisk fordelt;

$$P(X = x) = \binom{n}{x} p^x (1 - p)^{n-x}$$

Dersom  $X \sim Bin(n, p)$  så er

- $E(X) = np$
- $Var(X) = np(1 - p)$

- $\hat{p}(X_1, X_2, \dots, X_{m_1+m_2}) = \frac{U+V}{m_1+m_2}$
- $\hat{\hat{p}}(X_1, X_2, \dots, X_{m_1+m_2}) = 0.5\left(\frac{U}{m_1} + \frac{V}{m_2}\right)$

Forventningsrette:

- $E(\hat{p}) = p$
- $E(\hat{\hat{p}}) = p$

## Viktige reknereglar

Forventning til lineærkombinasjon:

$$E(a_0 + a_1 X_1 + \dots + a_n X_n) = a_0 + a_1 E(X_1) + \dots + a_n E(X_n)$$

Varians til lineärfunksjon:

$$\text{Var}(a + bX_1) = b^2 \text{Var}(X_1)$$

Dersom  $X_1, X_2, \dots, X_n$  er **uavhengige**:

$$\text{Var}(a_0 + a_1 X_1 + a_2 X_2 + \dots + a_n X_n) = a_1^2 \text{Var}(X_1) + a_2^2 \text{Var}(X_2) + \dots + a_n^2 \text{Var}(X_n)$$

Antar uavhengigheit.

- $Var(\hat{p}) = Var\left(\frac{U + V}{m_1 + m_2}\right) = \frac{p(1-p)}{m_1 + m_2}$
- $Var(\hat{\hat{p}}) = Var\left(0.5\left(\frac{U}{m_1} + \frac{V}{m_2}\right)\right) = 0.25p(1-p)\left(\frac{1}{m_1} + \frac{1}{m_2}\right)$

Kan vise at

$$Var(\hat{\hat{p}}) - Var(\hat{p}) = p(1-p) \frac{(m_1 - m_2)^2}{4m_1 m_2 (m_1 + m_2)} \geq 0$$

Altså  $Var(\hat{\hat{p}}) \geq Var(\hat{p}) \Rightarrow$  foretrekker  $\hat{\hat{p}}$ .

Finn den verdien for parameteren  $\theta$  (studentpåske  $\theta = p$ ) som gjev høgast sannsyn for å observere dei dataene vi har observert.

## OPPSKRIFT

- Finn likelihoodfunksjonen

$$L(\theta; x_1, x_2, \dots, x_n) = f(x_1, x_2, \dots, x_n; \theta) \stackrel{uavh}{=} \prod_{i=1}^n f(x_i; \theta)$$

- Finn toppunkt av likelihoodfunksjonen:

- Tar ln av  $L$ ;  $I(\theta; x_1, x_2, \dots, x_n) = \ln(L(\theta; x_1, x_2, \dots, x_n))$ .

*Reknetriks som nesten alltid blir brukt.  $L$  og  $I$  har same toppunkt.*

- Deriverer og set lik 0;  $\frac{\partial}{\partial \theta} I(\theta; x_1, x_2, \dots, x_n) = 0$

- Løyser ut for  $\theta$ . *Skal eigentleg sjekke endepunkt og at det er eit topp-punkt og.*

- Har data  $x_1, x_2, \dots, x_n$
- Antar fordeling frå kjennskap til fenomenet;  $x_i \sim f(x; \theta)$ .
- *Estimerer/ berekner  $\theta$  frå data v.h.a. ein estimator  $\hat{\theta}$ .*
  - Kva er ein god estimator (**forventningsrett og minst mogeleg varians**).
  - Korleis finne ein estimalor (**SME**)
  - Kvantifisere usikkerheita i estimat (**konfidensintervall**)