



# Oppsummering del 2

Torstein Fjeldstad

Institutt for matematiske fag, NTNU

22.11.2018



- Repetisjon del 2
- Eksamensmai 2009 oppgåve 3



# DEL 2: Statistikk

# Sentralgrenseteoremet



Viss  $\bar{X}$  er gjennomsnittet av eit tilfeldig utval av storleik  $n$  tatt frå ein populasjon med forventningsverdi  $\mu$  og varians  $\sigma^2 < \infty$  vil

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \rightarrow n(z; 0, 1) \quad \text{når } n \rightarrow \infty.$$

# Estimator



Situasjon:  $X_1, X_2, \dots, X_n$  tilfeldig utval med  $X_i \sim f(x_i; \theta)$

Mål: ynskjer å anslå verdien til  $\theta$  (og seie noko om tilhøyrande uvisse)

**Observator:** funksjon av stokastiske variablar

**Estimator:** ein observator  $\hat{\theta}$  som nyttes til å estimere verdien til den ukjende parameteren  $\theta$

# Sannsynsmaksimering

Situasjon:  $X_1, X_2, \dots, X_n$  tilfeldig utval  $X_i \sim f(x_i; \theta)$

1. Definer rimelighetsfunksjonen

$$L(\theta) = \prod_{i=1}^n f(x_i; \theta)$$

2. Ofte er det enklare å sjå på log-rimelighetsfunksjonen

$$l(\theta) = \sum_{i=1}^n \ln f(x_i; \theta)$$

3. Maksimer  $l(\theta)$  (ofte ved å derivere og setje lik null)

## Eigenskapar til estimatorar



- Ynskjer ein forventningsrett (eng: unbiased) estimator

$$E(\hat{\theta}) = \theta$$

- For to forventningsrette estimatorar  $\hat{\theta}_1, \hat{\theta}_2$  vil me velge den med lågast varians:

$$\text{Var}(\hat{\theta}_1) < \text{Var}(\hat{\theta}) \Rightarrow \text{velg } \hat{\theta}_1$$

## $\chi^2$ -fordeling (kjikkvadratfordeling)

$$f(x) = \frac{1}{2^{\nu/2}\Gamma(\nu/2)} x^{\nu/2-1} e^{-x/2}, \quad x \geq 0, \quad \nu = 1, 2, \dots$$

$$\mathbb{E}(X) = \nu, \quad \text{Var}(X) = 2\nu, \quad M_X(t) = \left(\frac{1}{1-2t}\right)^{\nu/2} \text{ for } t < \frac{1}{2}.$$

Kommentar: Dersom  $X_1, \dots, X_n$  er uavhengige og normalfordelte med forventning  $\mu$  og varians  $\sigma^2$  har vi at

$$\sum_{i=1}^n \frac{(X_i - \mu)^2}{\sigma^2} \quad \text{er } \chi^2\text{-fordelt med } n \text{ frihetsgrader,}$$

$$\sum_{i=1}^n \frac{(X_i - \bar{X})^2}{\sigma^2} \quad \text{er } \chi^2\text{-fordelt med } n - 1 \text{ frihetsgrader,}$$

$$\sum_{i=1}^n (X_i - \bar{X})^2 \text{ og } \bar{X} \text{ er uavhengige.}$$

## $t$ -fordeling (Student $t$ -fordeling)

$$f(x) = \frac{\Gamma[(\nu+1)/2]}{\Gamma(\nu/2)\sqrt{\pi\nu}} \left(1 + \frac{x^2}{\nu}\right)^{-(\nu+1)/2}, \quad -\infty < x < \infty.$$

$$\mathbb{E}(X) = 0 \text{ hvis } \nu \geq 2, \quad \text{Var}(X) = \frac{\nu}{\nu-2} \text{ hvis } \nu \geq 3, \quad M_X(t) \text{ eksisterer ikke.}$$

Spesialtilfeller:  $\nu = 1$  gir Cauchyfordelingen.

$\nu = \infty$  gir Normalfordelingen.

Kommentar: Dersom  $Z$  er standard normalfordelt og  $V$  er  $\chi^2$ -fordelt med  $\nu$  frihetsgrader og  $Z$  og  $V$  er uavhengige, har vi at

$$\frac{Z}{\sqrt{V/\nu}} \quad \text{er } t\text{-fordelt med } \nu \text{ frihetsgrader.}$$

Spesielt gir dette at dersom  $X_1, \dots, X_n$  er uavhengige og normalfordelte med forventning  $\mu$  og varians  $\sigma^2$  har vi at

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \quad \text{er } t\text{-fordelt med } n - 1 \text{ frihetsgrader,}$$

$$\text{der } S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2.$$

## Fordeling til lineærkombinasjoner

La  $X_1, \dots, X_n$  være uavhengige variabler.

Dersom  $X_i$  er normalfordelt med forventning  $\mu_i$  og varians  $\sigma_i^2$  vil  $Y = \sum_{i=1}^n a_i X_i$  være normalfordelt med forventning  $\sum_{i=1}^n a_i \mu_i$  og varians  $\sum_{i=1}^n a_i^2 \sigma_i^2$ .

Dersom  $X_i$  er binomisk fordelt med parametre  $m_i$  og  $p$  vil  $Y = \sum_{i=1}^n X_i$  være binomisk fordelt med parametre  $\sum_{i=1}^n m_i$  og  $p$ .

Dersom  $X_i$  er Poissonfordelt med parameter  $\mu_i$  vil  $Y = \sum_{i=1}^n X_i$  være Poissonfordelt med parameter  $\sum_{i=1}^n \mu_i$ .

Dersom  $X_i$  er  $\chi^2$ -fordelt med  $\nu_i$  frihetsgrader vil  $Y = \sum_{i=1}^n X_i$  være  $\chi^2$ -fordelt med  $\sum_{i=1}^n \nu_i$  frihetsgrader.

# Konfidensintervall



Situasjon:  $X_1, X_2, \dots, X_n$  tilfeldig utval  $X_i \sim f(x_i; \theta)$

Mål: ynskjer konfidensintervall  $[\hat{\theta}_L(X_1, X_2, \dots, X_n), \hat{\theta}_U(X_1, X_2, \dots, X_n)]$   
slik at

$$P(\hat{\theta}_L(X_1, X_2, \dots, X_n) \leq \theta \leq \hat{\theta}_U(X_1, X_2, \dots, X_n)) = 1 - \alpha$$

## Generell framgangsmåte for konfidensintervall

- 
1. Estimator for  $\theta$ ,  $\hat{\theta}$  (t.d. SME)
  2. La  $Z = h(\hat{\theta}, \theta)$  der  $h(\cdot, \cdot)$  er ein funksjon s.a.  $Z$  har ei kjend fordeling.
  3. Har då

$$P(z_{1-\alpha/2} \leq h(\hat{\theta}, \theta) \leq z_{\alpha/2}) = 1 - \alpha$$

4. Løys ulikskapane (mhp.  $\theta$ ) kvar for seg og finn eit uttrykk med  $\theta$  i midten

$$P(\hat{\theta}_L(X_1, X_2, \dots, X_n) \leq \theta \leq \hat{\theta}_U(X_1, X_2, \dots, X_n)) = 1 - \alpha$$

5. Et  $(1 - \alpha) \cdot 100\%$  konfidensintervall for  $\theta$  er

$$[\hat{\theta}_L(X_1, X_2, \dots, X_n), \hat{\theta}_U(X_1, X_2, \dots, X_n)]$$

# Hypotesetesting



		$H_0$ riktig	$H_1$ riktig
Forkast $H_0$	Type I-feil	Ok	
Ikkje forkast $H_0$	Ok	Type II-feil	

Ide: vi må vere "sikre" før me påstår at  $H_1$  er rett. Me velg signifikansnivået  $\alpha$  liten og krev

$$P(\text{Type I-feil}) = P(\text{Forkast } H_0 \text{ når } H_0 \text{ er riktig}) \leq \alpha$$

$$\beta = P(\text{Type II-feil}) = P(\text{Ikkje forkast } H_0 \text{ når } H_1 \text{ er riktig})$$

# Generell framgangsmåte

Situasjon:  $X_1, X_2, \dots, X_n$  tilfeldig utval med  $X_i \sim f(x_i; \theta)$ .



1. Ynskjer å teste:
  - a)  $H_0 : \theta = \theta_0$  mot  $H_1 : \theta > \theta_0$
  - b)  $H_0 : \theta = \theta_0$  mot  $H_1 : \theta < \theta_0$
  - c)  $H_0 : \theta = \theta_0$  mot  $H_1 : \theta \neq \theta_0$
2. Estimator for  $\theta$ ;  $\hat{\theta}$
3. La  $Z = h(\hat{\theta}, \theta_0)$ , der  $h(\cdot, \cdot)$  er ein funksjon s.a.  $Z$  har ei kjend fordeling under  $H_0$
4. Bestem eit forkastningskriterium (antar  $Z$  stor når  $\hat{\theta}$  stor)
  - a) Forkast  $H_0$  dersom  $Z > k$
  - b) Forkast  $H_0$  dersom  $Z < k$
  - c) Forkast  $H_0$  dersom  $Z < k_l$  eller  $Z > k_u$   
der  $k$  bestemmes frå kravet
5. Sett inn tal og konkluder

$$P(\text{Forkast } H_0 \text{ når } H_0 \text{ er riktig}) \leq \alpha$$

## *p*-verdi

Ein *p*-verdi er det lågaste signifikansnivået  $\alpha$  slik at observert verdi for observatoren gjev at me skal forkaste  $H_0$ . Det vil seie, forkast  $H_0$  dersom *p*-verdien er *mindre* enn  $\alpha$ .

## Teststyrke

Styrken til ein test er sannsynet for å forkaste  $H_0$  gitt at ein spesifikk alternativ hypotese er sann.

$H_0$	Value of Test Statistic	$H_1$	Critical Region
$\mu = \mu_0$	$z = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}}$ ; $\sigma$ known	$\mu < \mu_0$	$z < -z_\alpha$
		$\mu > \mu_0$	$z > z_\alpha$
		$\mu \neq \mu_0$	$z < -z_{\alpha/2}$ or $z > z_{\alpha/2}$
$\mu = \mu_0$	$t = \frac{\bar{x} - \mu_0}{s/\sqrt{n}}$ ; $v = n - 1$ , $\sigma$ unknown	$\mu < \mu_0$	$t < -t_\alpha$
		$\mu > \mu_0$	$t > t_\alpha$
		$\mu \neq \mu_0$	$t < -t_{\alpha/2}$ or $t > t_{\alpha/2}$
$\mu_1 - \mu_2 = d_0$	$z = \frac{(\bar{x}_1 - \bar{x}_2) - d_0}{\sqrt{\sigma_1^2/n_1 + \sigma_2^2/n_2}}$ ; $\sigma_1$ and $\sigma_2$ known	$\mu_1 - \mu_2 < d_0$	$z < -z_\alpha$
		$\mu_1 - \mu_2 > d_0$	$z > z_\alpha$
		$\mu_1 - \mu_2 \neq d_0$	$z < -z_{\alpha/2}$ or $z > z_{\alpha/2}$
$\mu_1 - \mu_2 = d_0$	$t = \frac{(\bar{x}_1 - \bar{x}_2) - d_0}{s_p \sqrt{1/n_1 + 1/n_2}}$ ; $v = n_1 + n_2 - 2$ , $\sigma_1 = \sigma_2$ but unknown, $s_p^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}$	$\mu_1 - \mu_2 < d_0$	$t < -t_\alpha$
		$\mu_1 - \mu_2 > d_0$	$t > t_\alpha$
		$\mu_1 - \mu_2 \neq d_0$	$t < -t_{\alpha/2}$ or $t > t_{\alpha/2}$
$\mu_1 - \mu_2 = d_0$	$t' = \frac{(\bar{x}_1 - \bar{x}_2) - d_0}{\sqrt{s_1^2/n_1 + s_2^2/n_2}}$ ; $v = \frac{(s_1^2/n_1 + s_2^2/n_2)^2}{\frac{(s_1^2/n_1)^2}{n_1 - 1} + \frac{(s_2^2/n_2)^2}{n_2 - 1}}$ , $\sigma_1 \neq \sigma_2$ and unknown	$\mu_1 - \mu_2 < d_0$	$t' < -t_\alpha$
		$\mu_1 - \mu_2 > d_0$	$t' > t_\alpha$
		$\mu_1 - \mu_2 \neq d_0$	$t' < -t_{\alpha/2}$ or $t' > t_{\alpha/2}$
paired observations	$t = \frac{\bar{d} - d_0}{s_d/\sqrt{n}}$ ; $v = n - 1$	$\mu_D < d_0$	$t < -t_\alpha$
		$\mu_D > d_0$	$t > t_\alpha$
		$\mu_D \neq d_0$	$t < -t_{\alpha/2}$ or $t > t_{\alpha/2}$

# Lineær regresjon

Situasjon: observert  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$

Modell:

$$Y_i|x_i \sim n(y_i; \alpha + \beta x_i, \sigma)$$

Kan tilpasse  $\alpha, \beta, \sigma$

- Minste kvadraters metode (kun  $\alpha, \beta$ )
- Sannsynsmaksimering

La  $Y_1, \dots, Y_n$  være uavhengige variabler med samme varians  $\sigma^2$  og forventningsverdier

$$E(Y_i) = \alpha + \beta x_i, \quad i = 1, \dots, n.$$

Minste kvadratsumsestimatorene for  $\alpha$  og  $\beta$  er da

$$\hat{\beta} = \frac{\sum_{i=1}^n (x_i - \bar{x}) Y_i}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\sum_{i=1}^n (x_i - \bar{x})(Y_i - \bar{Y})}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad \hat{\alpha} = \bar{Y} - \hat{\beta} \bar{x},$$

og en forventningsrett estimator for  $\sigma^2$  er gitt ved

$$S^2 = \frac{1}{n-2} \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta} x_i)^2.$$

Dersom i tillegg  $Y_1, \dots, Y_n$  er normalfordelte vil

$$\frac{(n-2)S^2}{\sigma^2} = \frac{1}{\sigma^2} \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta} x_i)^2$$

være  $\chi^2$ -fordelt med  $n-2$  frihetsgrader. Det kan også vises at  $(n-2)S^2/\sigma^2$  er uavhengig av  $\hat{\alpha}$  og  $\hat{\beta}$ .

# Prediksjon lineær regresjon



Merk at det er skilnad på følgande:

- Forventa respons  $\mu_{Y|x_0}$
- Ein ny observasjon  $Y_0$  (gitt  $x_0$ )



# Eksamensmai 2009 oppgåve 3

# Eksamensmai 2009 oppgave 3



## Oppgave 3 Kontrastmiddel

Effekten av ulike typer kontrastmiddel brukt ved røntgenundersøkelsar av hender skal studerast. Kontrastmiddelet blir injisert i handflata før røntgenbiletet blir teke. Ein ynskjer å minske strålingsfaren ved å ta få bileter - helst berre eit av kvar hand.

For å måle effekten har ein utvikla eit kontrastmål for eit bilet av ei hand. Utan kontrastmiddel kallast målet  $K_0$  og det varierer frå person til person, men kan sjåast på som identisk for begge hendene på ein person. Tidligare erfaring tilseier at  $K_0$  er normalfordelt med forventningsverdi  $\mu_0$  og standardavvik  $\sigma_0$ . Det vil sei at  $K_0$  er  $n(k_0; \mu_0, \sigma_0)$ .

Gå no ut i frå at  $\mu_0$  og  $\sigma_0$  er ukjende. Ei studie på 10 forsøkspersonar blir brukt til å kartleggje kontrastmålet. Eit røntgenbilde utan bruk av kontrastmiddel blir teke av ei av hendene til kvar av dei 10 forsøkspersonane. Det resulterer i 10 uavhengige observasjonar av kontrastmålet  $K_0$ , sjå tabell 1.

Forsøksnr. $i$	1	2	3	4	5	6	7	8	9	10
$k_0(i)$	21	28	19	23	31	32	28	23	28	27

Tabell 1: Målt kontrast uten bruk av kontrastmiddel. Her blir  $\bar{k}_0 = 1/10 \sum_{i=1}^{10} k_0(i) = 26$  og  $\sum_{i=1}^{10} (k_0(i) - \bar{k}_0)^2 = 166$ .

- b) Utei eit 90% konfidensintervall for forventa kontrastmål  $\mu_0$ , og finn talsvar.

# Eksamensmai 2009 oppgave 3



Ved bruk av kontrastmiddel blir kontrasten i røntgenbileta endra slik at kontrastmålet blir:

$$K = K_0 + R$$

der  $R$  er effekten av kontrastmiddelet.

Gå ut i frå at  $R$  er normalfordelt med forventning  $\mu_R$  og standardavvik  $\sigma_R$ , dvs  $n(r; \mu_R, \sigma_R)$ . Vidare går vi ut i frå at  $K_0$  og  $R$  har ein korrelasjon på  $\rho_{0R}$ , og at  $K$  er normalfordelt  $n(k; \mu_K, \sigma_K)$ .

- c) Utlei uttrykk for forventninga  $\mu_K$  og standardavviket  $\sigma_K$  til kontrastmålet ved bruk av kontrastmiddel.

# Eksamensoppgave 3



Vi ønskjer no å samanlikne kontrastmåla ved bruk av to ulike kontrastmiddele, type A og type B. La effekten av kvar av desse vere  $R_A$  og  $R_B$ , og tilsvarende blir kontrastmåla:

$$K_A = K_0 + R_A$$

$$K_B = K_0 + R_B$$

Vi går ut i frå at alle variablane er normalfordelte, og at  $R_A$  og  $R_B$  er uavhengige. For å undersøke kontrastmåla for dei to ulike kontrastmiddele gjennomfører vi et forsokskoppligg: For kvar type blir det gjort 10 forsøk. For dei 20 forsøkspersonane blir kontrastmiddelet injisert i ei av hendene, eit røntgenbilde blir teke, og kontrastmålet blir registrert. Dette gjev eit sett av uavhengige observasjonar av  $K_A$  og  $K_B$ , sjå tabell 2 og 3.

Forsøk nr ( $i$ )	1	2	3	4	5	6	7	8	9	10
$k_A(i)$	29	38	26	32	40	43	37	31	38	36

Tabell 2: Målt kontrast ved bruk av kontrastmiddel A. Her blir  $\bar{k}_A = 1/10 \sum_{i=1}^{10} k_A(i) = 35$ .

Forsøk nr ( $i$ )	1	2	3	4	5	6	7	8	9	10
$k_B(i)$	44	37	46	40	33	29	36	42	35	38

Tabell 3: Målt kontrast ved bruk av kontrastmiddel B. Her blir  $\bar{k}_B = 1/10 \sum_{i=1}^{10} k_B(i) = 38$ .

Gå i punkt d) og e) ut i frå at standardavvik til  $K_0$  og  $R$  er kjende,  $\sigma_0 = 4$  og  $\sigma_R = 2$ , at korrelasjonen mellom  $K_0$  og  $R$  er kjend,  $\rho_{0R} = 5/16$ , og at standardavviket  $\sigma_R$  og korrelasjonen  $\rho_{0R}$  er lik for dei to kontrastmiddele, det vil sei  $\text{Var}(R_A) = \text{Var}(R_B) = 2^2$  og  $\text{Corr}(K_0, R_A) = \text{Corr}(K_0, R_B) = 5/16$ .

Følgjande hypoteser blir framsett: Forventa kontrastmål ved bruk av kontrastmiddel type A og type B er identiske. Denne hypotesen skal testast mot alternativet at dei to forventningane er ulike.

- d) Test hypotesen over på signifikansnivå 0.1 ved å bruke dataane i tabell 2 og 3.

Utlei styrken for denne testen for forskjell i forventa kontrastmål lik 2.