

# UNIVERSITETET I OSLO

## Det matematisk-naturvitenskapelige fakultet

- Eksamen i: STK1000 – Innføring i anvendt statistikk  
Eksamensdag: Tirsdag 30. november 2021  
Tid for eksamen: 15:00–19:00  
Oppgavesettet er på 6 sider.  
Vedlegg: Ingen  
Tillatte hjelpemidler: Alle hjelpemidler er tillatt, men det er ikke tillatt å kommunisere eller samarbeide med andre.

Kontroller at oppgavesettet er komplett før du begynner å besvare spørsmålene.

Opgavesettet har fire oppgaver som til sammen består av ti deloppgaver. Hver deloppgave teller likt.

### Oppgave 1 Passe bred

#### 1a

Anta at  $Y_1 \sim N(\mu_1, \sigma_1)$  og  $Y_2 \sim N(\mu_2, \sigma_2)$  er uavhengige og normalfordelte variabler. Da er

- i) summen  $Y_1 + Y_2$  normalfordelt, og
- ii) – forventningsverdien til summen  $Y_1 + Y_2$  er  $\mu_{Y_1+Y_2} = \mu_1 + \mu_2$   
– variansen til summen  $Y_1 + Y_2$  er  $\sigma_{Y_1+Y_2}^2 = \sigma_1^2 + \sigma_2^2$ , og  
– standardavviket til summen  $Y_1 + Y_2$  er  $\sigma_{Y_1+Y_2} = \sqrt{\sigma_1^2 + \sigma_2^2}$

#### 1b

Det er gitt at  $\sigma_1 = \sigma_2 = 0,05$ . Standardavviket til realisert bredde  $Z$  er  $\sigma_Z = \sigma_{M+\epsilon_2} = \sqrt{\sigma_M^2 + \sigma_{\epsilon_2}^2} = \sqrt{\sigma_1^2 + \sigma_2^2} = \sqrt{2} \cdot 0,05 = 0,07$ .

(Merk at  $Z$  ikke er standard normalfordelt selv om den heter 'Z'. Det er selvfølgelig like fint om en student velger å døpe om  $Z$  til feks  $R$ , dersom de foretrekker å reservere bokstaven  $Z$  til en standard normalfordelt variabel.)

#### 1c

Du skulle skjære hylleplata for å sette den i et skap med innvendig bredde 80,00 cm.

(Fortsettes på side 2.)

- i) Realisert bredde  $Z$  er normalfordelt med forventning  $\mu_Z = B$  og standardavvik  $\sqrt{2} \cdot 0,05$ , så når  $B = 80,00$  er

$$P(Z < B) = P(Z < \mu_Z) = P(\tilde{Z} < 0) = 0,5 \quad (1)$$

for en standard normalfordelt variabel  $\tilde{Z}$ , eller rett og slett fordi alle normalfordelinger er symmetriske om forventningsverdien.

- ii) Vi ønsker å finne  $B$  slik at 95% percentilen til  $Z$  er 80,0. Vi vet at 95% percentilen til  $Z$  uttrykt ved  $B$  er

$$Z_{0,95} = B + z_{0,95} \cdot \sigma_Z \quad (2)$$

der  $z_{0,95}$  er 95% percentilen til en standard normalfordelt variabel. Når vi setter uttrykket for 95% percentilen til  $Z$  (høyre side i ligning 1) lik 80,0 og løser for  $B$  får vi

$$B = 80,00 - z_{0,95} \cdot \sigma_Z = 80,00 - 1.644854 \cdot \sqrt{2} \cdot 0.05 = 79.88. \quad (3)$$

## Oppgave 2 Par av tilfeldige variabler

Anta at du har 100 par av variabler,  $(X_1, Y_1)$ ,  $(X_2, Y_2)$ ,  $\dots$ ,  $(X_{100}, Y_{100})$ , der alle de 200 tilfeldige variablene er uavhengige, og  $X_j \sim N(\mu_X, \sigma)$ ,  $Y_j \sim N(\mu_Y, \sigma)$ .

### 2a

I denne deloppgaven antar vi  $P(X_j > Y_j) = 0.5$  for hvert par  $j$

- i) Definer for hvert par 'suksess' dersom det første elementet er det største.

Antall par  $N$  der det første elementet er det største, er da antall suksesser over 100 uavhengige forsøk, der hvert forsøk har suksesssannsynlighet 0.5.

$N$  er dermed binomisk fordelt  $N \sim Bin(n = 100, p = 0.5)$ .

- ii) Forventa antall par der det første elementet er det største er  $\mu_N = n \cdot p = 100 \cdot 0.5 = 50$

- iii) A: R-kommandoen 'pbinom(39,size=100,prob=0,5)' angir kumulativ andel 0,01760

B: Normalapprosimasjon med kontinuitetskorleksjon  $P(N < 40) = P(Z < \frac{39,5-50}{\sqrt{100 \cdot 0,5 \cdot 0,5}}) = P(Z < -2,1) = 0,01786$

- C. Det er mulig å bruke programvare for å beregne sannsynligheten ved bruk av det matematiske uttrykket

$$P(N = i) = \binom{100}{i} \cdot 0,5^{100}. \quad (4)$$

(Fortsettes på side 3.)

Ved å utnytte at  $P(N = j) = P(N = 100 - j)$ , kan man redusere antall ledd, og feks beregne

$$P(N < 40) = \frac{1 - P(N = 50)}{2} - \sum_{j=40}^{49} P(N = j) = 0,01760 \quad (5)$$

## 2b

I denne og den neste deloppgaven, antar vi ikke lenger at  $\mu_X = \mu_Y$

- i) Den parvise differansen  $X_j - Y_j$  i hvert par er normalfordelt, slik at  $X_j - Y_j \sim N(\mu_X - \mu_Y, \sqrt{2} \cdot \sigma)$ .
- ii) Differansen mellom utvalgsgjennomsnittene  $\bar{X} - \bar{Y}$  er normalfordelt  $N(\mu_X - \mu_Y, \sqrt{2} \cdot \frac{\sigma}{10})$  fordi variansen

$$\sigma_{\bar{X}-\bar{Y}}^2 = \sigma_{\bar{X}}^2 + \sigma_{\bar{Y}}^2 = \sigma_X^2/n_X + \sigma_Y^2/n_Y = \frac{\sigma^2 + \sigma^2}{100} = 2 \cdot \left(\frac{\sigma}{10}\right)^2 \quad (6)$$

## 2c

Vi velger å gjennomføre en statistisk hypotesetest på  $\alpha = 5\%$  signifikansnivå. Nullhypotese:  $H_0 : \mu_X = \mu_Y$ , (tosidig) alternativ-hypotese  $H_0 : \mu_X \neq \mu_Y$ .

Under  $H_0$  er  $\mu_X = \mu_Y$  og standardisert testobservator er

$$T = \frac{\bar{X} - \bar{Y} - (\mu_X - \mu_Y)}{s_{\bar{X}-\bar{Y}}} = \frac{\bar{X} - \bar{Y} - 0}{s_{\bar{X}-\bar{Y}}/\sqrt{100}} = \frac{\bar{X} - \bar{Y}}{s_{\bar{X}-\bar{Y}}/10} \quad (7)$$

Setter inn  $\bar{X} = 10,02$ ,  $\bar{Y} = 10,98$  og  $s_{\bar{X}-\bar{Y}} = 4,73$ , og får

$$T = \frac{10,02 - 10,98}{4,73/10} = -2,029598. \quad (8)$$

T-fordelinga med 99 frihetsgrader gir da tosida P-verdi  $2 \cdot 0,0225 = 0,045$ .

Med statistisk signifikansnivå  $\alpha = 5\%$ , har vi observert en p-verdi 0,045 som er mindre enn signifikansnivået  $\alpha$ .

Vi forkaster nullhypotesen til fordel for alternativhypotesen, og konkluderer at forventningsverdiene  $\mu_X$  og  $\mu_Y$  er ulike.

## Oppgave 3 Forhold mellom kroppsmål

### 3a

- i) En enkel lineær regresjonsmodell for responsvariabel kroppslengde ( $y_i$ ) og forklaringsvariabelen fot.navle ( $x_i$ ), er

$$y_i = \beta_0 + \beta_1 \cdot x_i + \epsilon_i, \quad i = 1, 2, \dots, 223 \quad (9)$$

der individuell variasjon  $\epsilon_i \sim N(0, \sigma)$  er uavhengig og normalfordelt for hvert av individene.

Modellantagelsene er dermed:

(Fortsettes på side 4.)

- 1) Forventa kroppslengde  $\mu_{y_i} = \beta_0 + \beta_1 \cdot x_i$  er **lineært** avhengig av verdien på forklaringsvariabelen fot.navle  $x_i$ .
  - 2) Spredninga i kroppslengde  $y_i$  er gitt ved standardavvik  $\sigma$  i underpopulasjonen der fot.navle har verdi  $x_i$ , for enhver verdi av  $x_i$ ; med andre ord, **spredninga** om forventningsverdien **varierer ikke med forklaringsvariabelen**  $x_i$ .
  - 3) Leddene for individuell variasjon,  $\epsilon_i$ ,  $i = 1, 2, \dots, 223$  er **uavhengige**. Ekvivalent: gitt verdiene til fot.navle-målene  $x_i$  for hvert individ, er kroppslengdene  $y_i$  uavhengige, og
  - 4) Leddene for individuell variasjon,  $\epsilon_i$ ,  $i = 1, 2, \dots, 223$  er **normalfordelte**. Ekvivalent: Gitt verdien til fot.navle-målet  $x_i$  for individ  $i$ , er kroppslengden  $y_i$  normalfordelt.
- ii) – Parameteren  $\beta_0$  er konstantleddet i lineærmodellen, og beskriver forventa kroppslengde for et individ med fot.navle-mål  $x_i = 0$ .
- Parameteren  $\beta_1$  er stigningstallet i lineærmodellen, og beskriver forventa antall enheter (cm) økning i kroppslengde  $y_i$  når fot.navle-målet øker med én enhet (cm).
- Parameteren  $\sigma$  beskriver spredninga i kroppslengde  $y_i$  om forventningsverdien  $\mu_{y_i}$ , der  $\mu_{y_i}$  bestemmes av forklaringsvariabelen  $x_i$ .
- iii) Estimatet til parameteren  $\beta_0$  er  $b_0 = 38.9$ . Estimatet til parameteren  $\beta_1$  er  $b_1 = 1.27$ . Estimatet til parameteren  $\sigma$  er  $s = 3.6$ .

### 3b

- i) Et 95% konfidensintervall for  $\beta_1$  er gitt ved  $b_1 \pm t^* SE_{b_1}$ , der  $t^*$  er 97.5%-persentilen til t-fordelinga med 221 frihetsgrader;  $t^* = 1,970756$ .  
 $b_1 - t^* SE_{b_1} = 1,197651$  og  $b_1 + t^* SE_{b_1} = 1,347389$ .  
 Et 95% konfidensintervall for  $\beta_1$  er dermed  $[1.20, 1.35]$ .
- ii) `predict(fit, newdata = data.frame(fot.navle=104.0), interval= 'confidence', level= 0.95)`
- iii) `predict(fit, newdata = data.frame(fot.navle=104.0), interval= 'predict', level= 0.95)`
- iv) – Et 95% konfidensintervall for  $\beta_1$  er et intervall av mulige verdier, i samsvar med dataene, for stigningstallet (forventa antall enheter (cm) økning i kroppslengde  $y_i$  per enhet økning i fot.navle-målet). Videre er konfidensintervallet er konstruert med en metode som i 95% av tilfellene metoden blir brukt, vil konstruere et intervall som inneholder den sanne verdien av populasjonsparameteren  $\beta_1$ .
- Et 95% konfidensintervall for forventa kroppslengde  $\mu_y$  av et individ med fot.navle lik 104, er et intervall av mulige verdier, i samsvar med dataene, for forventa kroppslengde for et tilfeldig

(Fortsettes på side 5.)

individ med angitt verdi for forklaringsvariabelen fot.navle lik 104,0. Videre er konfidensintervallet konstruert med en metode som i 95% av tilfellene metoden blir brukt, vil konstruere et intervall som inneholder den sanne forventningsverdien  $\mu_y$  i underpopulasjonen av individer med fot.navle-mål  $x_i = 104,0$ .

- Et 95% prediksjonsintervall for kroppshøydemål  $y_i$  når fot.navle-målet er 104,0, er et intervall av mulige verdier av responsvariabelen kroppshøydemål for individer med fot.navle-mål lik 104,0cm. Videre, er et 95% prediksjonsintervall konstruert med en metode som i 95% av tilfellene metoden blir brukt, vil konstruere et intervall som inneholder responsverdien  $y$  for en tilleggsobservasjon med kjent verdi av forklaringsvariabelen fot.navle-mål  $x$ . Prediksjonsintervallet inkluderer variabiliteten i en fremtidig observasjon om forventningsverdien i underpopulasjonen av individer med fot.navle-mål lik  $x_i = 104,0$ , og prediksjonsintervallet for kroppslengde blir derfor bredere enn konfidensintervallet for forventta kroppslengde.

## Oppgave 4 Snø til jul

Sjansen for snø til jul for Frank varierer med kalenderår og om han er på hytta.

### 4a

En logistisk regresjonsmodell for sammenhengen mellom responsvariabelen ‘snø til jul’ ( $y$ ) og forklaringsvariablene kalenderår ( $X_1$ ) og ‘jul på hytta’ ( $X_2$ ), er

$$\log\left(\frac{p_i}{1-p_i}\right) = \beta_0 + \beta_1 \cdot x_{i1} + \beta_2 \cdot x_{i2} \quad (10)$$

der  $p_i$  er sannsynligheten  $P(y_i = 1)$  for snø til jul for individ  $i$  med kjent verdi  $x_1, x_2$  for forklaringsvariablene. Videre er

- $\beta_1$  er den naturlige logaritmen av odds-ratioen for snø til jul for et års økning i kalenderår
- $\beta_2$  er den naturlige logaritmen av odds-ratioen for snø til jul for jul på hytta sammenligna med i hovedstanden.

### 4b

Et 95% kondensintervall for parameteren  $\beta_2$  er gitt ved formelen

$$b_0 \pm z_{0,975} \cdot SE_{b_0} \quad (11)$$

(Fortsettes på side 6.)

der  $z_{0,975}$  er 97.5% persentilen til en standard normalfordelt variabel. Det gir at

$$[0.76152 - 1.96 \cdot 0.84862, 0.76152 + 1.96 \cdot 0.84862] = [-0.9017752, 2.424815] \quad (12)$$

er et 95% kondensintervall for parameteren  $\beta_2$ .

Siden  $\beta_2$  er den naturlige logaritmen av odds-ratioen for snø til jul for jul på hytta sammenligna med i hovedstanden, er et 95% kondensintervall for odds-ratioen for snø til jul på hytta sammenligna med hjemme for Frank for et gitt kalenderår bestemt av 95% konfidensintervallet til parameteren  $\beta_2$ , som

$$e^{b_0 \pm z_{0,975} \cdot SE_{b_0}}. \quad (13)$$

Et 95% kondensintervall for odds-ratioen for snø til jul på hytta sammenligna med hjemme, er

$$[e^{-0.9017752}, e^{2.424815}] = [0.41, 11.30]. \quad (14)$$

Vi konkluderer med at Frank har en høyst usikker effekt av å reise på hytta, med tanke på sannsynligheten for snø til jul.