

# UNIVERSITETET I OSLO

## Det matematisk-naturvitenskapelige fakultet

Eksamen i: STK1000 — Innføring i anvendt statistikk - kortfattet fasit

Eksamensdag: Mandag 3. desember 2018.

Tid for eksamen: 14.30–18.30.

Oppgavesettet er på 2 sider.

Vedlegg: Ingen

Tillatte hjelpemidler: Lærebok Moore, McCabe & Craig: Introduction to the practice of statistics. Det er tillatt å notere i læreboka, men ikke lov å klistre inn notater. Ordliste. Kapittel 14, som deles ut. Godkjent kalkulator.

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

Det er fire oppgaver med til sammen ti del-spørsmål. Hvert del-spørsmål teller likt.

### Oppgave 1.

a)  $P(X > 1) = 1 - P(X \leq 1) = 1 - P(Z \leq \frac{1-0}{0.5}) = 1 - 0.9772 = 0.0228.$

b) Må først komme frem til at  $W \sim N(\mu, \sqrt{\sigma_X^2 + \sigma_Y^2})$ , innsatt  $W \sim N(2, 1.58)$ . Finner så  $P(W > 3) = 1 - P(W \leq 3) = 1 - P(Z \leq \frac{3-2}{1.58}) = 1 - 0.7357 = 0.2643.$

### Oppgave 2.

a) Antar at vi har to uavhengige tilfeldige utvalg, og at de  $n_1 = 21$  uavhengige observasjonene  $x_{1i}$  fra mais-populasjonen kommer fra en normalfordeling med forventning  $\mu_1$  og at de  $n_2 = 24$  uavhengige observasjonene  $x_{2j}$  fra bomulls-populasjonen kommer fra en normalfordeling med forventning  $\mu_2$ .

Tester hypotesene  $H_0 : \mu_1 - \mu_2 = 0$  mot  $H_a : \mu_1 - \mu_2 \neq 0$

Siden den empiriske variansen til bomulls-utvalget er ca. 14 ganger større enn variansen til mais-utvalget, er det ikke naturlig å anta lik varians. Vi bruker derfor en to-utvalgs-t-observator på formen

$$t = \frac{(\bar{x}_1 - \bar{x}_2)}{\sqrt{s_1^2/n_1 + s_2^2/n_2}}$$

der  $\bar{x}_1$  og  $\bar{x}_2$  er gjennomsnittet i de to gruppene, og  $s_1^2$  og  $s_2^2$  er de to empiriske

(Fortsettes på side 2.)

variansene. Når  $H_0$  er riktig, er denne test-observatoren tilnærmet t-fordelt, med tilnærmet  $k$  frihetsgrader, der  $k$  finnes fra programvare (R).

b) Vi bruker den første t-testen, som ikke antar lik varians. Antall frihetsgrader er beregnet til 26.57. Verdien på t-observatoren ovenfor er 8.3477, og tilhørende p-verdi for hypotesene ovenfor er  $6.67 \cdot 10^{-9}$ . Vi forkaster  $H_0$  og konkluderer med at det er forskjell i avstanden mellom øynene for de to diettene, på ethvert rimelig signifikansnivå.

c) Et 95% konfidensintervall for forskjellen finnes ved  $(\bar{x}_1 - \bar{x}_2) \pm t^* \sqrt{s_1^2/n_1 + s_2^2/n_2}$ , der  $t^* = 2.056$  hvis vi bruker tilnærmet 26 frihetsgrader (fra R). Gir konfidensintervallet (0.3800, 0.6284). Dvs. større avstand mellom øynene for fluene som ble alet opp på mais.

**Oppgave 3.** Estimert odds-ratio er  $OR = e^{0.78} = 2.18$ , og vi kan konkludere med at en enhets økning i  $x$  omtrent doubler oddsen for å finne mineralet. Konfidensintervallet for odds-ratio  $e^{\beta_1}$  finnes ved å transformere et konfidensintervall for  $\beta_1$ , og vi får formelen  $(e^{b_1 - z^* SE_{b_1}}, e^{b_1 + z^* SE_{b_1}})$ . For et 95% konfidensintervall har vi  $z^* = 1.96$  og intervallet blir (1.83, 2.60).

#### Oppgave 4.

a) Korrelasjonen finnes som roten av Multiple R-squared i utskriften, dvs. 0.776. Positiv fordi  $b_1$  er positiv.  $b_0 = 0.175$ ,  $b_1 = 0.00319$ .  $b_1$  er estimert endring i forventet gjennomsnittlig is-konsum per hode for en økning på 1 grad Celsius i ukes-temperaturen.  $s = 0.0241$ .

b) Alle koeffisienter er signifikante, normalfordelingsplottet stemmer rimelig godt med normalfordelingsantakelsen, det er ingen mønster i residualplottet, så antakelser om linearitet og konstant varians OK. Bør begrunne kort hvorfor plottene er ok (kommentere mulig outlier). Modellen passer rimelig bra med dataene. At  $R^2 = 0.6016$  betyr at ca. 60% av variasjonen i responsvariabelen (gj. snittlig isforbruk per hode) kan forklares av den lineære sammenhengen med forklaringsvariabelen (ukestemperatur).

c)  $SE_{b_1} = 0.00319/6.502 = 0.00049$ . 28 frihetsgrader gir konfidensintervallet (0.00219, 0.00419) for  $\beta_1$ . Siden 0 ikke er i 95%-konfidensintervallet, kan vi forkaste  $H_0 : \beta_1 = 0$  og konkludere med den tosidige  $H_a : \beta_1 \neq 0$  på signifikansnivå 0.05 (stemmer med p-verdien i utskriften).

d) Fra utskriften finner vi prediksjonsintervallet (0.2075, 0.3138) liter i uken (95% er default). Men  $x = 27$  ligger klart utenfor det området vi har data for. Det er ikke sikkert at vi vil ha en lineær sammenheng for høye temperaturer. Noe tvilsom ekstrapolasjon.

SLUTT