

Fasit endelig eksamen STK1000

Høsten 2011

Oppgave 1

(a) $X \sim \text{bin}(150, 0.08)$, $\mu_X = 150 \cdot 0.08 = 12$, $\sigma_X = \sqrt{150 \cdot 0.08 \cdot 0.92} = 3.32$

(b) Tilnærmet $X \sim N(12, 3.32)$. $P(X \geq 15) = P(Z \geq 0.90) = 1 - P(Z < 0.90) = 1 - 0.8159 = 0.1841$ (her er $Z \sim N(0, 1)$). Normalfordelingen regnes som god tilnærming til $\text{bin}(n, p)$ når $np > 10$ og $n(1 - p) > 10$. Oppfylt her.

Oppgave 2

(a) Parret fordi to påfølgende fredager i samme måned er mer like enn tilfeldige fredager. Ved å bruke differansen mellom 6. og 13. i samme måned reduserer vi effekten av sesongvariasjoner i biltrafikken. Se s. 410 i boken. Antakelser: samme antakelser som for vanlig ett-utvalgs-t-test skal her gjelde for differansene. Bør ha uavhengige, tilnærmet normalfordelte differanser. La $X =$ trafikk den 6. – trafikk den 13., dvs. differanse innen hvert par. Antar X tilnærmet $\sim N(\mu, \sigma)$. Parameteren av interesse er da forventet differanse μ . Hvis $\mu = 0$ er det ingen forskjell.

(b) $H_0 : \mu = 0$ mot $H_a : \mu > 0$. Vi skal finne ut om folk holder seg hjemme den 13. Derfor velger vi $H_a : \mu > 0$, som betyr at det er forventet færre biler ute den 13. enn den 6. Estimert $\hat{\mu} = \bar{x} = 2022$ (Mean for Difference i utskriften). Estimert standardavvik til \bar{x} er $s/\sqrt{5} = 1539/\sqrt{5} = 688$ (s finnes som StDev for Difference i utskriften).

(c) Testobservator $t = \frac{\bar{x}-0}{s/\sqrt{5}} = \frac{2022}{688} = 2.94$ som stemmer med utskriften. Vi har $5-1=4$ frihetsgrader. P-verdien finnes som $P(T > 2.94)$ der T er t-fordelt med 4 frihetsgrader. Fra tabellen finner vi at $0.02 < P\text{-verdi} < 0.025$, som stemmer med $P=0.021$ fra utskriften. Denne P-verdien er mindre enn 0.05, og vi forkaster H_0 . Forventet trafikk på M25 er mindre på fredag den 13. enn på fredagen før ($P=0.021$).

Oppgave 3

(a) Data (x_i, y_i) , $i = 1, \dots, 54$, for PCB-innhold og skalltykkelse. Modell:

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i$$

der ϵ_i er uavhengige og normalfordelte $N(0, \sigma)$, $i = 1, \dots, 54$. Parametre er β_0 , β_1 og σ . Estimer $b_0 = 0.377$, $b_1 = -0.000309$ og $s = 0.05925$. For $x^* = 200$ får vi $\hat{\mu}_y = 0.31483$.

- (b) $H_0 : \beta_1 = 0$ mot $H_a : \beta_1 \neq 0$. Testobservator $t = b_1/SE_{b_1} = -2.43$. P-verdi fra utskrift 0.019, som er mindre enn 0.05. Med signifikansnivå 0.05 får vi forkastning av H_0 og konkluderer med at det er en signifikant lineær sammenheng mellom PCB og eggeskalltykkelse.
- (c) r^2 angir andelen av variasjonen i y som kan forklares av regresjonen av y på x . Med $r^2 = 0.102$ kan bare ca. 10% av variasjonen i skalltykkelse forklares av den lineære sammenhengen med PCB-innhold. Dette gir oss svært usikre prediksjoner.
- (d) Har: California, $N(\mu_1, \sigma)$: $n_1 = 54$, $\bar{x}_1 = 203.04$, $s_1 = 64.02$ og Florida, $N(\mu_2, \sigma)$: $n_2 = 48$, $\bar{x}_2 = 176.51$, $s_2 = 59.89$. To-utvalgs-t med lik varians gir konfidensintervall for $\mu_1 - \mu_2$ som

$$\bar{x}_1 - \bar{x}_2 \pm t^* s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

der s_p finnes fra formel s. 442 i boken. Finner $s_p = 62.1131$. For t-fordeling med $n_1 + n_2 - 2 = 100$ frihetsgrader og 99% konfidens finner vi $t^* = 2.626$. Innsatt får vi et 99% konfidensintervall for $\mu_1 - \mu_2$ som $(-5.83, 58.89)$.

- (e) Et 99% konfidensintervall for $\mu_1 - \mu_2$ kan brukes til å teste

$$H_0 : \mu_1 - \mu_2 = 0 \quad \text{mot} \quad H_a : \mu_1 - \mu_2 \neq 0$$

på nivå 0.01. Siden $\mu_1 - \mu_2 = 0$ er inneholdt i intervallet, kan vi ikke forkaste H_0 .