

LØSNING, EKSAMEN I STATISTIKK, TMA4240, DESEMBER 2006

OPPGAVE 1

Anta at sann porøsitet er r . Måling med utstyret gir da $X \sim n(x; r, 0,03)$.

a)

$$P(X > r) = P\left(\frac{X - r}{0,03} > 0\right) = P(Z > 0) = 0,5.$$

$$P(X - r > 0,05) = P\left(\frac{X - r}{0,03} > \frac{0,05}{0,03}\right) = P(Z > 1,67) = 0,0475.$$

For de som tolket feilen som absoluttverdi (som også er rimelig)

$$P(|X - r| > 0,05) = P\left(\frac{|X - r|}{0,03} > \frac{0,05}{0,03}\right) = P(|Z| > 1,67) = 0,0950.$$

Anta at X_1 og X_2 er uavhengig identisk fordelt (uif). Da er $\bar{X} = \frac{1}{2}(X_1 + X_2) \sim n(\bar{x}; r, 0,03/\sqrt{2})$.

$$P(\bar{X} - r > 0,05) = P\left(\frac{\bar{X} - r}{0,03/\sqrt{2}} > \frac{0,05}{0,03/\sqrt{2}}\right) = P(Z > 2,357) = 0,0092.$$

For de som tolket avviket som absoluttverdi (som også er rimelig)

$$P(|\bar{X} - r| > 0,05) = P\left(\frac{|\bar{X} - r|}{0,03/\sqrt{2}} > \frac{0,05}{0,03/\sqrt{2}}\right) = P(|Z| > 2,357) = 0,0184.$$

b) X_1, X_2, \dots, X_5 er uif $n(x; 0,15, \sigma)$.

Den beste (mest effektive) forventningsrette estimatoren er $\hat{\sigma}^2 = \frac{1}{5} \sum_{i=1}^5 (X_i - 0,15)^2$. Dette er sannsynlighetsmaksimeringsestimatoren. (NB: $\mu = 0,15$ er kjent!)

Vi har at

$$\frac{n\hat{\sigma}^2}{\sigma^2} = \frac{5\hat{\sigma}^2}{\sigma^2} = \sum_{i=1}^5 \left(\frac{X_i - 0,15}{\sigma}\right)^2 = \sum_{i=1}^5 Z_i^2 = V_5 \sim \chi_5^2.$$

Uttrykket er kji-kvadratfordelt ("chi-square") med 5 frihetsgrader.

$$E\left(\frac{5\hat{\sigma}^2}{\sigma^2}\right) = E(V_5) = 5 \quad \text{dvs} \quad \frac{5}{\sigma^2} E(\hat{\sigma}^2) = 5, \quad \text{og dermed} \quad E(\hat{\sigma}^2) = \sigma^2.$$

$$\text{Var}\left(\frac{5\hat{\sigma}^2}{\sigma^2}\right) = \text{Var}(V_5) = 2 \cdot 5 = 10 \quad \text{dvs} \quad \frac{25}{\sigma^4} \text{Var}(\hat{\sigma}^2) = 10, \quad \text{og dermed} \quad \text{Var}(\hat{\sigma}^2) = 0,4\sigma^4.$$

95%-konfidensintervall for σ^2 : $P(\chi_{5,0,975}^2 < V_5 < \chi_{5,0,025}^2) = 0,95$.

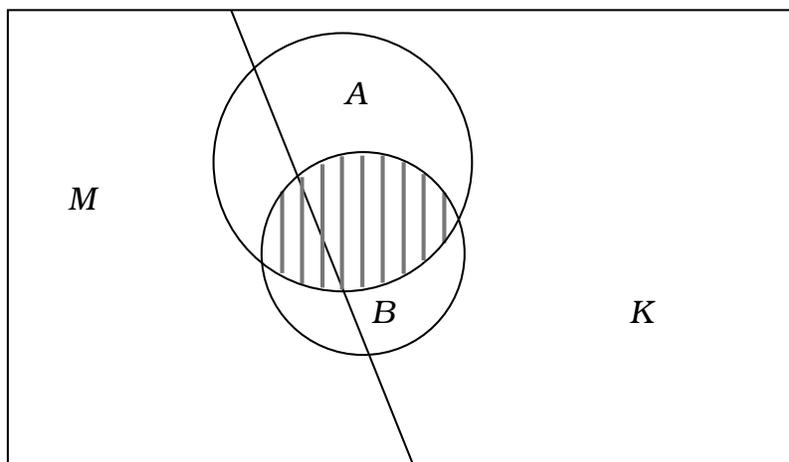
$$P\left(\chi_{5,0,975}^2 < \frac{5\hat{\sigma}^2}{\sigma^2} < \chi_{5,0,025}^2\right) = 0,95,$$

$$P\left(\frac{5\hat{\sigma}^2}{\chi_{5,0,275}^2} < \sigma^2 < \frac{5\hat{\sigma}^2}{\chi_{5,0,975}^2}\right) = 0,95.$$

Med $\hat{\sigma} = 0,0177$, $\chi_{5,0,025}^2 = 12,833$ og $\chi_{5,0,975}^2 = 0,831$ blir konfidensintervallet for σ^2 $[0,000122, 0,00188]$. Det tilsvarer konfidensintervall for σ : $[0,0110, 0,0434]$.

OPPGAVE 2

a)



Figur 1: Venn-diagram for hendelsene M , K , A og B . Merk at M og K deler utfallsrommet i to disjunkte deler, mens A og B delvis overlapper M , K og hverandre. $A \cap B$ er vertikalt skravert.

Vi benytter at vi summerer sannsynlighet for disjunkte hendelser, og at snittene kan skrives ut med betinget sannsynlighet.

$$P(A \cap K) = P(A|K)P(K) = 0,440 \cdot \frac{418}{632} = 0,2910,$$

30% av respondentene var kvinner som hadde utøvd psykologisk aggresjon mot partneren.

$$P(A) = P(A \cap M) + P(A \cap K) = P(A|M)P(M) + P(A|K)P(K) = 0,272 \cdot \frac{214}{632} + 0,440 \cdot \frac{418}{632} = 0,0921 + 0,2910 = 0,3831,$$

38% av respondentene hadde utøvd psykologisk aggresjon mot partneren, dvs når vi også inkluderer mennene.

b) For $P(K|A)$ bruker vi egentlig Bayes' formel, men beregningen over gir oss tallene vi

trenger direkte.

$$P(K|A) = \frac{P(K \cap A)}{P(A)} \left(= \frac{P(A|K)P(K)}{P(A|M)P(M) + P(A|K)P(K)} \right) = \frac{0,2910}{0,3831} = 0,7596.$$

Sannsynligheten for at skjemaet er fylt ut av en kvinne er hele 76%. Dette skyldes dels at flere kvinner enn menn svarte på undersøkelsen, dels at større andel kvinner enn menn rapporterte A .

For $P(A|B)$ bruker vi igjen Bayes' formel, og bruker at $B = (A \cap B) \cup (A^* \cap B)$.

$$\begin{aligned} P(A|B) &= \frac{P(A \cap B)}{P(B)} = \frac{P(A \cap B \cap K) + P(A \cap B \cap M)}{P(B|K)P(K) + P(B|M)P(M)} \\ &= \frac{P(A \cap B|K)P(K) + P(A \cap B|M)P(M)}{[P(A \cap B|K) + P(A^* \cap B|K)]P(K) + [P(A \cap B|M) + P(A^* \cap B|M)]P(M)} \\ &= \frac{0,292 \cdot 0,6614 + 0,216 \cdot 0,3386}{[0,292 + 0,148] \cdot 0,6614 + [0,216 + 0,056] \cdot 0,3386} = 0,6950. \end{aligned}$$

Eventuelt kan en selvfølgelig regne ut $P(B|K) = P(A \cap B|K) + P(A^* \cap B|K)$ osv. først, eller til og med regne ut antall personer i hver kategori og løse oppgaven derfra.

70% av respondentene som har opplevd psykologisk aggresjon fra partneren, har selv også utøvd psykologisk aggresjon, de resterende 30% er kanskje mer "uskyldige" offer?

c) Hendelsen X er binomisk fordelt hvis:

- hvert skjema kan karakteriseres som suksess (S) eller fiasko (S^*) - ingen tvilstilfeller,
- det er et fiksert antall $n = 418$ skjema i undersøkelsen, hvor suksessene telles i X ,
- sannsynligheten for S , $P(S|K)$ er den samme for hvert skjema fylt ut av en kvinne; vi kan altså ikke på forhånd dele bunken i skjema hvor vi tror det er mange S og skjema med få S ,
- besvarelsene er uavhengige; respondentene har ikke påvirket hverandre.

Dette er rimelige antakelser, så vi bruker binomisk fordeling for X (og Y).

Hvis andelen x/n fra undersøkelsen gjelder hele populasjonen (av kvinnelige studenter i heterogene parforhold), er $p_X = x/n = 38/418$. Dine fem venninner antas trukket tilfeldig med binomisk fordeling som over, med $p = P(S|K) = 38/418 = 0,0909$. (Altså, ca. 1 av 10 har opplevd seksuell aggresjon fra partner.) $n = 5$ gir punktsannsynligheten

$$P(X \geq 1) = 1 - P(X = 0) = 1 - \binom{5}{0} p^0 (1-p)^{5-0} = 1 - (1 - 0,0909)^5 = 0,3790 = 38\%.$$

d) Vi kan tilnærme binomisk til normal hvis $np_X > 5$ og $n(1-p_X) > 5$ og tilsvarende $mp_Y > 5$ og $m(1-p_Y) > 5$. Den minste av disse ser ut til å være mp_Y , men $m\hat{p}_Y = 10$ er stor nok.

$$\text{Var}(\hat{p}_X) = \text{Var}(X/n) = \text{Var}(X)/n^2 = np_X(1 - p_X)/n^2 = p_X(1 - p_X)/n.$$

$$\text{Var}(\hat{p}_Y) = \text{Var}(Y/m) = \text{Var}(Y)/m^2 = mp_Y(1 - p_Y)/m^2 = p_Y(1 - p_Y)/m.$$

Eventuelt kan en legge til at vi har et gjennomsnitt av indikatorvariabler, og at sentralgrenseteoremet gir at $\frac{\hat{p}_X - p_X}{\sqrt{p_X(1-p_X)/n}} \sim N(0, 1)$ når $n \rightarrow \infty$ og tilsvarende for p_Y og m .

En rimelig estimator for andelen S hvis H_0 er sann er $\hat{p} = \frac{X+Y}{n+m} = \frac{38+10}{632} = 0,0759$. Dermed setter vi inn $p = p_X = p_Y \approx \hat{p} = 0,0759$ i variansuttrykkene.

Med $H_0 : p_X = p_Y$ og $H_1 : p_X \neq p_Y$ har vi en tosidig hypotesetest. Testobservatoren er $\hat{p}_X - \hat{p}_Y$, som under H_0 har forventningsverdi $p_X - p_Y = 0$ og varians $\sigma^2 = p_X(1 - p_X)/n + p_Y(1 - p_Y)/m = p(1 - p)(1/n + 1/m) \approx 0,0223^2$. Vi aksepterer H_0 hvis observatoren havner mellom $-z_{\alpha/2}\sigma$ og $z_{\alpha/2}\sigma$. Med $\alpha = 0,05$ blir akseptområdet $|\hat{p}_X - \hat{p}_Y| < 1,645 \cdot 0,0223 = 0,0366$.

Vi har $\hat{p}_X - \hat{p}_Y = 38/418 - 10/214 = 0,0442$, som er utenfor akseptområdet. Dermed forkastes H_0 på signifikansnivå 0.05, og vi er enige med rapporten. (Det er grunn til å tro at flere kvinner opplever seksuell aggresjon fra sin mannlige partner enn motsatt.)

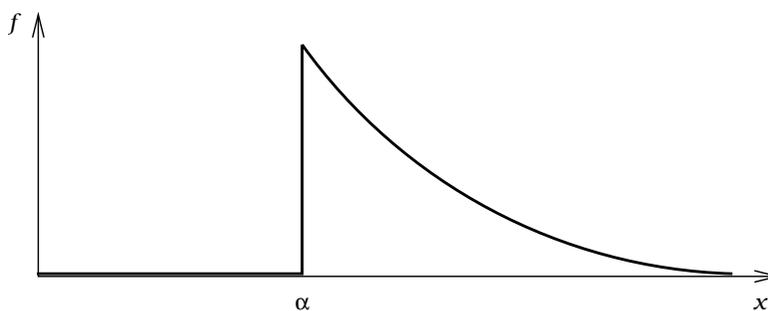
Vi har altså fått $z_{\text{obs}} = \frac{\hat{p}_X - \hat{p}_Y}{\sigma} = \frac{0,0442}{0,0223} = 1,9841$. Arealet over denne verdien i standard normalfordelingen er halvparten av p-verdien, siden vi har en tosidig test.

$$P\text{-verdi} = 2P(Z > 1,9841) = 2P(Z < -1,9841) \approx 2 \cdot \frac{0,0239+0,0233}{2} = 0,0472 = 4,72\%.$$

Bruk av $\sigma \approx \sqrt{\hat{p}_X(1 - \hat{p}_X)/n + \hat{p}_Y(1 - \hat{p}_Y)/m}$ gir omtrent samme resultat. Merk at dette er en dårligere approksimasjon av σ under H_0 .

OPPGAVE 3

a)



Figur 2: Skisse av sannsynlighetstettheten $f(x; \alpha, \beta)$.

Sannsynlighetsmaksimering for β følger normal prosedyre, men en bør huske at $x_i \geq \alpha$ for

alle x_i .

$$L(\alpha, \beta; x_1, \dots, x_n) = \begin{cases} 0, & \text{hvis minst én } x_i < \alpha, \\ \prod_{i=1}^n \frac{1}{\beta} e^{-(x_i - \alpha)/\beta}, & \text{ellers.} \end{cases}$$

$$\Lambda(\alpha, \beta; x_1, \dots, x_n) = -n \ln(\beta) - \sum_{i=1}^n \frac{x_i - \alpha}{\beta}, \quad \text{når alle } x_i \geq \alpha.$$

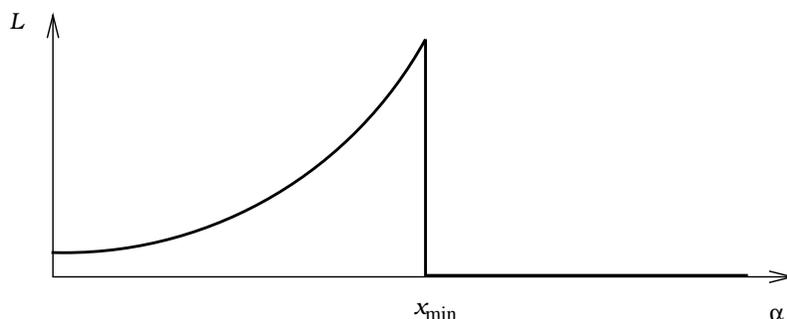
$$\frac{\partial \Lambda}{\partial \beta} = -\frac{n}{\beta} + \sum_{i=1}^n \frac{x_i - \alpha}{\beta^2}.$$

$\frac{\partial \Lambda}{\partial \beta} = 0$ for $\beta = \hat{\beta}$ og stokastiske variabler for målingene x_i gir

$$\hat{\beta} = \frac{1}{n} \sum_{i=1}^n (X_i - \alpha) = \bar{X} - \alpha,$$

hvor \bar{X} er gjennomsnittet $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$.

b)



Figur 3: Skisse av likelihoodfunksjonen som funksjon av α . Vi vet at $\alpha > 0$ fra oppgaven, funksjonen vokser eksponensielt i starten, og at den blir null hvis α er større enn grensen definert av minste X -verdi. Poenget er at funksjonen ikke er deriverbar mhp α i toppunktet, så vi kan ikke derivere og sette lik null som før. Oppgaven krever ikke at denne figuren er med.

Vi skal altså finne en α som maksimerer

$$L(\alpha, \beta; x_1, \dots, x_n) = \begin{cases} 0, & \text{hvis minst én } x_i < \alpha, \\ \left(\frac{1}{\beta}\right)^n \exp\left[-\frac{\sum_{i=1}^n x_i - n\alpha}{\beta}\right], & \text{ellers.} \end{cases}$$

Det er klart at vi må velge $\alpha \leq \min(x_i)$, ellers er $L = 0$ fra den første linja i den delte forskriften. Den andre linja blir størst hvis α er så stor som mulig. Derfor maksimeres L av $\hat{\alpha} = \min(X_1, \dots, X_n)$.

Sannsynlighetsmaksimeringsestimatoren for β har vi fra forrige oppgave. Siden α er ukjent må vi prøve $\hat{\beta} = \bar{X} - \hat{\alpha}$.

For å finne forventningsverdien til $\hat{\alpha}$, brukes transformasjonen $Z_i = X_i - \alpha$. Dette skyver fordelingen inntil andreaksen, slik at vi får en standard eksponensialfordeling med parameter β . Hintet sier at $\min(Z_1, \dots, Z_n)$ har forventningsverdi β/n .

Den minste X -verdien er α større enn den minste Z -verdien, siden $X_i = Z_i + \alpha$ også for den i -en som gir minst X_i . Dermed er $E(\hat{\alpha}) = \alpha + \beta/n$, og ikke forventningsrett.

Forventningsverdien til X er $\alpha + \beta$, det er jo bare en vanlig eksponensialfordeling med forventning β som er flyttet α til høyre på x -aksen. Forventningsverdien til \bar{X} er $E(\bar{X}) = \frac{1}{n} \sum_{i=1}^n E(X_i) = E(X_i) = \alpha + \beta$. Hvis vi bytter ut α med $\hat{\alpha}$ i uttrykket for estimatoren, blir forventningsverdien

$$E(\hat{\beta}) = E(\bar{X}) - E(\hat{\alpha}) = \alpha + \beta - E(\hat{\alpha}) = \beta(1 + \frac{1}{n}) = \frac{n+1}{n}\beta.$$

Denne er heller ikke forventningsrett.

Her kan vi fikse estimatoren for β ved å gange med $n/(n+1)$, og deretter justere estimatoren for α . Vi vil demonstrere en annen framgangsmåte (som gir samme resultat). Trekk fra $\hat{\beta}/n$ i estimatoren for α . Da blir $\hat{\alpha}$ forventningsrett hvis $\hat{\beta}$ er forventningsrett. Til sammen har vi da to likninger som gjelder for forventningsrette estimatorene:

$$\begin{aligned}\hat{\alpha} &= \min(X_1, \dots, X_n) - \frac{\hat{\beta}}{n}, \\ \hat{\beta} &= \bar{X} - \hat{\alpha}.\end{aligned}$$

Dette likningssystemet kan løses, og vi ender opp med

$$\begin{aligned}\hat{\alpha} &= \frac{n}{n-1} \min(X_1, \dots, X_n) - \frac{1}{n-1} \bar{X}, \\ \hat{\beta} &= \frac{n}{n-1} (\bar{X} - \min(X_1, \dots, X_n)) = \frac{1}{n-1} \sum_{i=1}^n X_i - \frac{n}{n-1} \min(X_1, \dots, X_n).\end{aligned}$$

Til slutt bør vi forsikre oss om at metoden over faktisk gir forventningsrette estimatorene:

$$\begin{aligned}E(\hat{\alpha}) &= \frac{n}{n-1} E(\min(X_1, \dots, X_n)) - \frac{1}{n-1} E(\bar{X}) \\ &= \frac{n}{n-1} (\alpha + \frac{\beta}{n}) - \frac{1}{n-1} (\alpha + \beta) = \alpha, \\ E(\hat{\beta}) &= \frac{1}{n-1} \sum_{i=1}^n E(X_i) - \frac{n}{n-1} E(\min(X_1, \dots, X_n)) \\ &= \frac{1}{n-1} n(\alpha + \beta) - \frac{n}{n-1} (\alpha + \frac{\beta}{n}) = \beta.\end{aligned}$$