

LØSNING: Eksamen 28. mai 2015

“MAT110 Statistikk 1”, vår 2015

Oppgave 1: (revisjon)

- a) Situasjonen som beskrives i oppgaven kan modelleres med en urne. I denne urnen er fordelingen kjent, M antall bilag med feil og $N = 100\,000$ bilag totalt. Den stokastiske variabelen X har derfor en hypergeometrisk fordeling.

- b) Siden X er hypergeometrisk fordelt så er forventningen:

$$E[X] = n \frac{M}{N} \quad (1)$$

Løser med hensyn på M alene og får:

$$\underline{M} = \frac{E[X]N}{n} = \frac{10 \cdot 100\,000}{1000} = \underline{1000} \quad , \quad \text{q.e.d.} \quad (2)$$

- c) Siden X er hypergeometrisk fordelt så er variansen:

$$\underline{Var}[X] = \frac{N-n}{N-1} n \frac{M}{N} \left(1 - \frac{M}{N}\right) \quad (3)$$

$$= \frac{100\,000 - 1000}{100\,000 - 1} 1000 \frac{1000}{100\,000} \left(1 - \frac{1000}{100\,000}\right) = \underline{9.8} \quad (4)$$

og tilhørende standardavvik:

$$\underline{\underline{\sigma[X]}} = \sqrt{\text{Var}[X]} = \sqrt{9.8} = \underline{\underline{3.13}} \text{ , q.e.d.} \quad (5)$$

- d)** i) En hypergeometrisk fordeling kan med god tilnærming beskrives av en normalfordeling dersom:

$$N \gtrsim 20 \cdot n \quad (6)$$

$$n \frac{M}{N} \left(1 - \frac{M}{N}\right) \gtrsim 5 \quad (7)$$

- ii) For vårt tilfelle er:

$$100\,000 \gtrsim 20 \cdot 1000 \quad (8)$$

$$1000 \frac{1000}{100\,000} \left(1 - \frac{1000}{100\,000}\right) \gtrsim 5 \quad (9)$$

som gir

$$100\,000 \gtrsim 20\,000 \quad (10)$$

$$9.9 \gtrsim 5 \quad (11)$$

dvs. kriteriene er oppfylte i vårt tilfelle.

- e)** og **g)** Se vedlegg.

- f) I oppgaven er det oppgitt at den stokastiske variabelen X er normalfordelt med $X \sim N[E[X] = 10, \sigma[X]]$. Dermed løses denne oppgaven med (omvendt) tabelloppslag ¹. Standardiserer:

$$P(X \geq g) = 0.10 \quad (12)$$

$$P\left(\underbrace{\frac{X - E[X]}{\sigma[X]}}_{\equiv Z} \geq \underbrace{\frac{g - E[X]}{\sigma[X]}}_{\equiv Z_0}\right) \stackrel{\text{standardiser}}{=} 0.10 \quad (13)$$

$$P(Z \geq Z_0) = 0.10 \quad (14)$$

Ulikheten skal være “rett vei”, altså mindre enn eller lik:

$$P(Z \geq Z_0) = 0.10 \quad (15)$$

$$1 - P(Z < Z_0) = 0.10 \quad (16)$$

$$P(Z < Z_0) = 0.90 \quad (17)$$

Ved “[omvendt tabelloppslag](#)” ser vi at Z_0 må være 1.28: ²

$$Z_0 = 1.28 \quad (19)$$

Vi løser

$$Z_0 = \frac{g - E[X]}{\sigma[X]} \quad (20)$$

med hensyn på g : ($E[X] = 10$ og $\sigma[X] = 3.13$ fra oppgave **c**)

$$\underline{g} = E[X] + Z_0 \cdot \sigma[X] \quad (21)$$

$$= 10 + 1.28 \cdot 3.13 = \underline{14} \quad (22)$$

¹Husk at tabellen på side 65 i 2015-formelsamlingen dreier seg KUN om normalfordeling.

²For en kontinuerlig sannsynlighetsfordeling er sannsynligheten i et punkt lik null. Dermed kan vi skrive:

$$P(Z \leq Z_0) = P(Z < Z_0) + \underbrace{P(Z = Z_0)}_{=0} = P(Z < Z_0) \quad (18)$$

Dermed kan vi finne fortsatt bruke tabellen i formelsamlingen selv om tabellen sier noe om $G(Z_0) \equiv P(Z \leq Z_0)$ mens vi skal finne $P(Z < Z_0)$.

Dette betyr at revisoren underkjenner regnskapet dersom han finner 14 feil eller mer blant de $n = 1000$ bilagene han trekker.



Oppgave 2: (økonomi / logistikk)

- a) Siden den stokastiske variabelen D_1 er oppgitt i oppgaven til å være **normalfordelt** så finner vi sannsynligheten $P(D_1 > 21\,000)$ ved standardisering og tilhørende tabelloppslag:

$$\underline{P(D_1 > 21\,000)} \stackrel{\text{standardiser}}{=} P\left(\underbrace{\frac{D_1 - \mu_1}{\sigma_1}}_{= Z} > \frac{21\,000 - \mu_1}{\sigma_1}\right) \quad (23)$$

$$= P\left(Z > \frac{21\,000 - 15\,000}{3000}\right) \quad (24)$$

$$= P(Z > 2) \quad (25)$$

$$= 1 - P(Z \leq 2) \quad (26)$$

$$= 1 - \underbrace{G(2)}_{= 0.9772} \quad (27)$$

$$\stackrel{\text{tabell}}{=} 1 - 0.9772 \quad (28)$$

$$= \underline{0.0228} \quad (29)$$

Sannsynligheten for at mer enn 21 000 trofaste aviskjøpere kjøper Dagbladet en gitt dag er 2.28 %.

- b) Det er oppgitt i oppgaven at den totale etterspørselen D_{tot} av aviser dersom det har skjedd en spesiell nyhet er:

$$D_{tot} = D_1 + D_2 \quad (30)$$

Ved å bruke formel (5.13) i formelsamlingen fra 2015 finner vi da:

$$\underline{\underline{E[D_{tot}]}} = E[D_1 + D_2] \quad (31)$$

$$\stackrel{\text{alltid}}{=} \underbrace{E[D_1]}_{=\mu_1} + \underbrace{E[D_2]}_{=\mu_2} = \mu_1 + \mu_2 = 15\,000 + 18\,000 = \underline{\underline{33\,000}} \quad (32)$$

NB: Overgangen i lign.(31) til (32) gjelder **alltid**. Uansett om de stokastiske variablene X_i er uavhengige eller ikke.

- c) Variansen til den totale etterspørselen D_{tot} av aviser dersom det har skjedd en spesiell nyhet er:

$$\underline{\underline{Var[D_{tot}]}} = Var[D_1 + D_2] \quad (33)$$

$$\stackrel{\text{uavh.}}{=} Var[D_1] + Var[D_2] \quad (34)$$

$$= \sigma_1^2 + \sigma_2^2 = 3000^2 + 4000^2 = \underline{\underline{25\,000\,000}} \quad (35)$$

NB: Overgangen fra lign.(33) til lign.(34) gjelder *kun* dersom de stokastiske variablene D_1 og D_2 er uavhengige.

- d) Forventede fortjenesten til Dagbladet $E[F]$ per dag dersom en spesiell nyhet har skjedd:

$$\underline{\underline{E[F]}} = E[(p - k)D_{tot} - c] \quad (36)$$

$$= (p - k)E[D_{tot}] - c = ((25 - 12) \cdot 33\,000 - 400\,000) \text{ NOK} \quad (37)$$

$$= \underline{\underline{29\,000 \text{ NOK}}} \quad (38)$$

Her har vi brukt at $E[D_{tot}] = 33\,000$ fra oppgave **2b**, se lign.(32).

- e) Siden D_{tot} er oppgitt i oppgaven til å være **normalfordelt** så finner vi sannsynligheten $P(D_{tot} > 21\,000)$ ved standardisering og tilhørende tabelloppslag: (bruker at $\sigma[D_{tot}] = \sqrt{\text{Var}[D_{tot}]} = \sqrt{25\,000\,000} = 5000$ fra oppgave **2c**)

$$\underline{\underline{P(D_{tot} > 21\,000|S)}} \stackrel{\text{standardiser}}{=} P\left(\underbrace{\frac{D_{tot} - E[D_{tot}]}{\sigma[D_{tot}]}}_{= Z_{tot}} \middle| S > \frac{21\,000 - 33\,000}{5000}\right) \quad (39)$$

$$= P\left(Z_{tot} > \frac{21\,000 - 33\,000}{5000}\right) \quad (40)$$

$$= P(Z_{tot} > -2.4) \quad (41)$$

$$= 1 - P(Z_{tot} \leq -2.4) \quad (42)$$

$$= 1 - \left(1 - P(Z_{tot} \leq 2.4)\right) \quad (43)$$

$$= P(Z_{tot} \leq 2.4) \quad (44)$$

$$\stackrel{\text{tabell}}{=} G(2.4) \quad (45)$$

$$= \underline{\underline{0.9918}} \quad (46)$$

Sannsynligheten for at mer enn 21 000 personer kjøper Dagbladet en gitt dag, dersom vi vet at det har skjedd en spesielle nyhet, er 99.18 %.

- f) Oppgaven spør etter sannsynligheten $P(D_{tot} > 21\,000)$.
Oppsplitting av utfallsrom Ω :³

$$\underbrace{P(D_{tot} > 21\,000)}_{\text{oppspl.}} \stackrel{\text{oppspl.}}{=} \underbrace{P(D_{tot} > 21\,000|S)}_{=0.9918} \cdot \overbrace{P(S)}^{=0.20} + \underbrace{P(D_{tot} > 21\,000|\bar{S})}_{=P(D_1 > 21\,000) = 0.028} \cdot \overbrace{P(\bar{S})}^{=1-0.20} \quad (47)$$

$$= 0.9918 \cdot 0.20 + 0.0228 \cdot (1 - 0.20) = \underline{0.2166} \quad (48)$$

Sannsynligheten for at det en gitt dag etterspørres mer enn 21 000 aviser dersom vi ikke vet om det skjer en spesiell nyhet eller ikke den aktuelle dagen, er 21.66 %.

■

³Se side 32 i formelsamlingen 2015.

Oppgave 3: (petroleumslogistikk)

a) Siden

$$\underline{\underline{\sum_{i=0}^n P(X = x_i)}} = P(X = 0) + P(X = 1) + P(X = 2) + P(X = 3) + P(X = 4) \quad (49)$$

$$= 0.09 + 0.28 + 0.41 + 0.17 + 0.05 = \underline{\underline{1}} \quad (50)$$

b) Sannsynligheten for at det leveres inn 3 rapporter eller mer per dag:

$$\underline{\underline{P(X \geq 3)}} = P(X = 3) + P(X = 4) = 0.17 + 0.05 = \underline{\underline{0.22}} \quad (51)$$

c) i) **Forventet** antall innleverte rapporter per dag:

$$\underline{\underline{E[X]}} \stackrel{\text{def.}}{=} \sum_{i=0}^4 x_i \cdot P(X = x_i) \quad (52)$$

$$= 0 \cdot \underbrace{P(X = 0)}_{=0.09} + 1 \cdot \underbrace{P(X = 1)}_{=0.28} + 2 \cdot \underbrace{P(X = 2)}_{=0.41} + 3 \cdot \underbrace{P(X = 3)}_{=0.17} + 4 \cdot \underbrace{P(X = 4)}_{=0.05}$$

$$= 0 \cdot 0.09 + 1 \cdot 0.28 + 2 \cdot 0.41 + 3 \cdot 0.17 + 4 \cdot 0.05 = \underline{\underline{1.81}} \quad (53)$$

ii) For å finne **variansen** $Var[X]$ så regner vi først ut $E[X^2]$:

$$\underline{\underline{E[X^2]}} \stackrel{\text{def.}}{=} \sum_{i=0}^3 x_i^2 \cdot P(X = x_i) \quad (54)$$

$$= 0^2 \cdot \underbrace{P(X = 0)}_{=0.09} + 1^2 \cdot \underbrace{P(X = 1)}_{=0.28} + 2^2 \cdot \underbrace{P(X = 2)}_{=0.41} + 3^2 \cdot \underbrace{P(X = 3)}_{=0.17} + 4^2 \cdot \underbrace{P(X = 4)}_{=0.05}$$

$$= 0^2 \cdot 0.09 + 1^2 \cdot 0.28 + 2^2 \cdot 0.41 + 3^2 \cdot 0.17 + 4^2 \cdot 0.05 = \underline{\underline{4.25}} \quad (55)$$

Dette innsatt i setningen for ‘*varianssetningen*’: ⁴

$$\underline{\underline{Var[X]}} = E[X^2] - E[X]^2 = 4.25 - 1.81^2 = \underline{\underline{0.9739}} \quad (56)$$

d) i) Tolkning:

$E[\bar{X}]$ = forventet antall innleverte rapporter per dag i gjennomsnitt over et helt år

ii) Forventet antall innleverte rapporter i gjennomsnitt per dag: ($n = 365$)

$$\underline{\underline{E[\bar{X}]}} = E\left[\frac{1}{n}\left(X_1 + X_2 + \dots + X_n\right)\right] \quad (57)$$

$$\stackrel{\text{alltid}}{=} \frac{1}{n}\left(E[X_1] + E[X_2] + \dots + E[X_n]\right) \quad (58)$$

$$= \frac{1}{n}\left(\underbrace{E[X] + E[X] + \dots + E[X]}_{= n \cdot E[X]}\right) = \frac{1}{n} \cdot \underbrace{E[X]}_{= 1.81} = \underline{\underline{1.81}} \quad (59)$$

NB: Overgangen i lign.(57) til (58) gjelder **alltid**. Uansett om de stokastiske variablene X_i er uavhengige eller ikke.

⁴Se side 39 i formelsamlingen fra 2015.

e) i) Tolkning:

$$\underline{\underline{Var[\bar{X}]} = \text{forventet variasjon/spredning i antall innleverte rapporter per dag}} \\ \underline{\underline{\text{i gjennomsnitt over et helt \u00e5r}}} \quad (60)$$

ii) Variansen til antall innleverte rapporter per dag i gjennomsnitt over et \u00e5r: ($n = 365$)

$$\underline{\underline{Var[\bar{X}]} = Var\left[\frac{1}{n}\left(X_1 + X_2 + \dots + X_n\right)\right]} \quad (61)$$

$$\stackrel{\text{uavh.}}{=} \frac{1}{n^2} \left(\underbrace{Var[X_1] + Var[X_2] + \dots + Var[X_n]}_{n \cdot Var[X]} \right) \quad (62)$$

$$= \frac{1}{n^2} \cdot \underbrace{Var[X]}_{=0.9739} = \frac{0.9739}{365} = \underline{\underline{0.002668}} \quad (63)$$

NB: Overgangen i lign.(61) til (62) gjelder fordi de stokastiske variablene X_i er uavhengige.

f) Siden

1. antall innleverte rapporter per dag er uavhengige: (oppgitt i oppgaveteksten)
 $X_i \sim$ er uavhengige for alle $i = 1, 2, 3, \dots, n$
2. alle X_i har samme sannsynlighetsfordeling: (oppgitt i oppgaveteksten)
 $X_i \sim$ samme sannsynlighetsfordeling for alle $i = 1, 2, 3, \dots, n$
3. antall "fors\u00f8k", dvs. antall dager, $n = 365$ er tilstrekkelig stort ⁵

s\u00e5 gjelder **sentralgrensesetningen**. Dermed er \bar{X} normalfordelt.

⁵Husk: Antall fors\u00f8k n for at sentralgrensesetningen skal gjelde er avhengig av situasjonen. Men en **tommel-fingerregel** er at vi b\u00f8r ha $n \gtrsim 30$.

g) Fra oppgavene **2c**, **2d** og **2e** foran ser vi at:

$$\underbrace{E[\bar{X}]}_{= 1.81} = \underbrace{E[X]}_{= 1.81} \quad (64)$$

og at

$$\underbrace{Var[\bar{X}]}_{= 0.002668} \ll \underbrace{Var[X]}_{= 0.9739} \quad (65)$$

Det betyr at sannsynlighetfordelingen til X , dvs. $P(X = x)$ gitt ved tabell i oppgaveteksten, og sannsynlighetfordelingen til \bar{X} , dvs. $\bar{X} \sim N[E[X], \sqrt{\frac{Var[X]}{n}}]$ har **samme tyngdepunkt**, men mye **mindre varians** / usikkerhet.

- h) Sannsynligheten for at antall innleverte rapporter i løpet av et år overstiger 700:
($n = 365$)

$$\underline{\underline{P(X_1 + X_2 + \dots + X_n > 700)}} = P\left(\frac{X_1 + X_2 + \dots + X_n}{n} > \frac{700}{n}\right) \quad (66)$$

$$= P\left(\bar{X} > \frac{700}{n}\right) \quad (67)$$

$$= 1 - P\left(\bar{X} \leq \frac{700}{n}\right) \quad (68)$$

$$\stackrel{\text{standardiser}}{=} 1 - P\left(\underbrace{\frac{\bar{X} - E[\bar{X}]}{\sigma[\bar{X}]}}_{=\bar{Z}} \leq \frac{\frac{700}{n} - E[\bar{X}]}{\sigma[\bar{X}]}\right) \quad (69)$$

$$= 1 - P\left(\bar{Z} \leq \frac{\frac{700}{365} - 1.81}{\sqrt{0.002668}}\right) \quad (70)$$

$$= 1 - P(\bar{Z} \leq 2.09) \quad (71)$$

$$= 1 - G(2.09) \quad (72)$$

$$= 1 - 0.9817 \quad (73)$$

$$= \underline{\underline{0.0183}} \quad (74)$$

Kommentar:

Legg merke til at det er \bar{X} som skal standardiseres. Ikke X . Det betyr at vi må bruke $E[\bar{X}] = 1.81$ og $\sigma[\bar{X}] = \sqrt{0.002668}$ (ikke $E[X] = 1.81$ og $\sigma[X] = \sqrt{0.9739}$).



Oppgave 4: (økonomi)

a) i) R_{xy} er normalisert og ligger mellom -1 og 1 , dvs.: $-1 < R_{xy} < 1$.

ii) R_{xy} er et mål på lineær korrelasjon mellom observasjonene x og y .
Det er et mål på i hvor stor grad det er en lineær sammenheng mellom observasjonene x og y .

iii) R_{xy} er enhetsuavhengig, dvs. ingen enhet. ⁶

b) Uttrykket for korrelasjonskoeffisienten finner vi i formelsamlingen. Det gir:

$$\underline{R_{xy}} = \frac{S_{xy}}{S_x \cdot S_y} \quad (75)$$

$$= \frac{-110.83}{\sqrt{116.67} \cdot \sqrt{109.54}} = \underline{\underline{-0.98}} \quad (76)$$

c) At $R_{xy} = -0.98$ betyr at det er en sterk negativ korrelasjon mellom x og y , dvs. store x hører sammen med små y og omvendt.
Det er altså en sterk lineær sammenheng mellom x og y med negativt stigningstall.

⁶ Dette betyr at R_{xy} har samme verdi uansett hva slags enhet man bruker for å regne ut $R_{xy} = S_{xy}/(S_x \cdot S_y)$.

- d) Vi skal finne regresjonslinjen. Formelen for minste kvadraters lineære regresjonslinje står i formelsamlingen:

$$\hat{y} = \hat{\alpha} + \hat{\beta}x \quad (77)$$

hvor parametrene $\hat{\beta}$ og $\hat{\alpha}$ er: (dropper benevningen)

$$\hat{\beta} = \frac{S_{xy}}{S_x^2} = \frac{-110.83}{116.67} = \underline{-0.95} \quad (78a)$$

$$\hat{\alpha} = \bar{y} - \beta\bar{x} = 40.43 - (-0.95) \cdot 15 = \underline{54.68} \quad (78b)$$

Minste kvadraters lineære regresjonslinje $\hat{y} = \hat{\alpha} + \hat{\beta}x$ blir dermed:

$$\underline{\underline{\hat{y} = 54.68 - 0.95 \cdot x}} \quad (79)$$

- e) Bruker regresjonslinjen $\hat{y} = \hat{y}(x)$ fra oppgave 4d, dvs. lign.(79):

$$\underline{\hat{y}(17)} = 54.68 - 0.95 \cdot 17 = \underline{38.53} \quad (80)$$

Regresjonslinjen predikerer at kvadratmeterprisen for en leilighet som er 17 km utenfor sentrum er 38 530 NOK/m².

- f) Gjennomsnittlig kvadratmeterpris i Norge er 35 000 NOK/ m^2 . Ifølge regresjonslinjen, når $\hat{y}(x) = 35$, er da:

$$35 = 54.68 - 0.95 \cdot x \quad (81)$$

Løser med hensyn på x :

$$\underline{x} = \frac{54.68 - 35}{0.95} = \underline{20.72} \quad (82)$$

Ifølge regresjonslinjen oppnår man landsgjennomsnittet i kvadratmeterpris 20.72 km utenfor sentrum.

- g) Forklaringskraften R^2 kan leses direkte fra Excel-utskriften:
(Se cellen som heter “*R Square*” i Excel-utskriften): ⁷

$$\underline{\underline{R^2 = 0.9613}} \quad (83)$$

- h) Kommentar til svaret i oppgave 4g:

At $R^2 = 0.9613$ betyr at regresjonslinjen vil i “i stor grad” **forutsi** kvadratmeterprisen på en leilighet for en gitt avstand fra sentrum.

Modellen har stor forklaringskraft.



⁷Man kan også regne ut forklaringskraften R^2 “for hånd” via definisjonen $R^2 = 1 - SSE/SST$. Men det er mye mer arbeidskrevende. Fint at dataprogrammer (som f.eks. Excel) kan hjelpe oss med slikt.

Vedlegg



Høgskolen i Molde
Vitenskapelig høgskole i logistikk

Studentnummer: _____

$f_X(x)$

