

ECON2130: EKSAMEN 2017v

SENSORVEILEDNING.

Det anbefales at de 9 deloppgavene merket med A, B, ... teller likt – uansett variasjon i vanskelighetsgrad. Svarene er gitt i << ... >>. Grensen til bestått bør ligge på ca 30-33%.

Oppgave 1

En vanlig kortstokk består av i alt 52 kort hvorav 12 er «billedkort». Billedkortene viser bilder av konge, dronning eller knekt, hver i fire «kortfarger», hjerter (♥) ruter (♦), kløver (♣) og spar (♠). De øvrige 40 kortene viser tallene 1 («Ess», som ikke betraktes som billedkort her), 2,...,10, som også er representert i de fire kortfargene.

Det trekkes 3 kort rent tilfeldig fra kortstokken. Kortene trekkes ett og ett uten tilbakelegging slik at i hver trekning har de gjenværende kortene samme sannsynlighet for å bli trukket. Det kan vises (som du ikke trenger å gjøre) at denne måten å trekke på leder til et rent tilfeldig utvalg slik at alle ikke-ordnede utvalg på tre kort har samme sjanse for å bli valgt.

La B_j betegne begivenheten at det trekkes et billedkort i trekning j (for $j=1,2,3$), og \bar{B}_j komplementet til B_j - dvs. at et annet kort enn billedkort blir trukket.

A. i) Finn sannsynlighetene $P(B_1)$, $P(B_1 \cap B_2)$ og $P(B_1 \cap B_2 \cap \bar{B}_3)$.

[Hint: Bruk f.eks. multiplikasjonssetningen på de to siste.]

ii) Tegn et Venn-diagram som viser at B_2 kan skrives som en disjunkt union

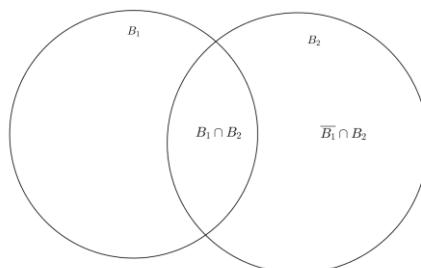
$$B_2 = (B_1 \cap B_2) \cup (\bar{B}_1 \cap B_2)$$

iii) Vis at $P(B_2) = \frac{3}{13}$. [Hint: Bruk ii)]

<< Svar: i): $P(B_1) = \frac{12}{52} = \frac{3}{13} = 0,231$, $P(B_1 \cap B_2) = P(B_1)P(B_2 | B_1) = \frac{12}{52} \cdot \frac{11}{51} = 0,050$,

$$P(B_1 \cap B_2 \cap \bar{B}_3) = P(B_1)P(B_2 | B_1)P(\bar{B}_3 | B_1 \cap B_2) = \frac{12}{52} \cdot \frac{11}{51} \cdot \frac{40}{50} = 0,040.$$

ii):



iii): $B_2 = (B_1 \cap B_2) \cup (\bar{B}_1 \cap B_2)$ $B_2 = (B_1 \cap B_2) \cup (\bar{B}_1 \cap B_2)$ disjunkt \Rightarrow

$$P(B_2) = P(B_1 \cap B_2) + P(\bar{B}_1 \cap B_2) = P(B_1)P(B_2 | B_1) + P(\bar{B}_1)P(B_2 | \bar{B}_1) =$$

$$= \frac{12}{52} \cdot \frac{11}{51} + \frac{40}{52} \cdot \frac{12}{51} = \frac{12}{52} \left(\frac{11}{51} + \frac{40}{51} \right) = \frac{12}{52} = \frac{3}{13}$$

>>

- B. La X være antall billedkort som blir trukket ut i et rent tilfeldig utvalg på tre kort fra kortstokken.

- i) Forklar kort hvorfor X er hypergeometrisk fordelt og sett opp en formel for $P(X = x)$, $x = 0, 1, 2, 3$.
- ii) Vis at $P(X = 0) = 0,447$ (med tre desimalers nøyaktighet). Finn også sannsynligheten for at det er minst ett billedkort i utvalget.
- iii) Vis, ved bruk av relevante formler for den hypergeometriske fordelingen, at forventningen til X er 0,692, og at standardavviket ($SD(X) = \sqrt{\text{var}(X)}$) til X er 0,715 (begge med tre desimalers nøyaktighet).

<< Svar: i): Det trekkes et utvalg på $n = 3$ kort fra en endelig populasjon av størrelse, $N = 52$ kort, hvorav $M = 12$ har kjennetegnet «billedkort». Hvis X er antall billedkort i utvalget, er det nok å vise til at utvalget er rent tilfeldig for å garantere at X er hypergeometrisk fordelt.

Punktsannsynlighetene blir

$$P(X = x) = \frac{\binom{12}{x} \binom{40}{3-x}}{\binom{52}{3}}, \quad x = 0, 1, 2, 3$$

ii)

$$P(X = 0) = \frac{\binom{12}{0} \binom{40}{3}}{\binom{52}{3}} = \frac{\binom{40}{3}}{\binom{52}{3}} = \frac{40 \cdot 39 \cdot 38 / 3!}{52 \cdot 51 \cdot 50 / 3!} = \frac{40 \cdot 39 \cdot 38}{52 \cdot 51 \cdot 50} = \frac{59280}{132600} = 0,44706\dots$$

Alternativ beregning er

$$P(X = 0) = P(\bar{B}_1 \cap \bar{B}_2 \cap \bar{B}_3) = P(\bar{B}_1)P(\bar{B}_2 | \bar{B}_1)P(\bar{B}_3 | \bar{B}_1 \cap \bar{B}_2) = \frac{40}{52} \cdot \frac{39}{51} \cdot \frac{38}{50} = 0,44706\dots$$

$$P(\text{"minst ett billedkort"}) = P(X > 0) = 1 - P(X = 0) = 0,553 \text{ med tre desimaler.}$$

iii):

$$E(X) = n \frac{M}{N} = 3 \cdot (0,2307...) = 0,692...$$

$$SD(X) = \sqrt{\text{var}(X)} = \sqrt{n \frac{M}{N} \left(1 - \frac{M}{N}\right) \frac{N-n}{N-1}} = \sqrt{3 \frac{12}{52} \left(1 - \frac{12}{52}\right) \frac{49}{51}} = 0,7153..$$

>>

- C. Følgende pengespill blir tilbudt: Spilleren betaler en spilleavgift på 75 kr. for hvert spill. Spillet består av at tre kort blir trukket rent tilfeldig fra en kortstokk som beskrevet i innledningen. For hvert billedkort som blir trukket ut får spilleren utbetalt 100 kr. Andre kort i utvalget som ikke er billedkort gir ingen utbetaling.

La U betegne spillerens gevinst etter et spill. For eksempel, hvis ingen billedkort blir trukket ut, taper spilleren spilleavgiften på 75 kr., som gir $U = -75$. Hvis alle tre kortene i utvalget blir billedkort, blir gevinsten 300 kr. – 75 kr. = 225 kr., som gir $U = 225$. Generelt kan vi uttrykke gevinsten som $U = 100X - 75$, der X er antall billedkort i utvalget som definert i punkt B.

- i) Vis at sannsynligheten for at spilleren får positiv gevinst i et spill ($P(U > 0)$) er lik 0,553 (med tre desimalers nøyaktighet).
- ii) Beregn forventningen og standardavviket for gevinsten (U) til spilleren etter et spill.
- iii) Hvis spilleren taper 75 kr i et spill, tjener tilbyderen 75 kr. Hvis, på den annen side, spilleren får en gevinst på f.eks. 225 kr, taper tilbyderen samme beløp. La V betegne tilbyderens fortjeneste etter et spill. Vi kan dermed uttrykke tilbyderens fortjeneste etter et spill som $V = -U = 75 - 100X$.

Vis at tilbyderens fortjeneste i et spill (V) har forventning 5,8 og standardavvik 71,5 (begge med en desimals nøyaktighet).

<< **Svar:** i): Vi har $U > 0 \Leftrightarrow 100X - 75 > 0 \Leftrightarrow X > \frac{75}{100} = 0,75 \Leftrightarrow X \geq 1$ siden

X bare kan ta hele verdier. Dermed

$$P(U > 0) = P(X \geq 1) = 1 - P(X = 0) \stackrel{\text{punkt B}}{=} 1 - 0,447 = 0,553$$

$$\text{ii): } E(U) = E(100X - 75) \stackrel{\text{regel 4.12}}{=} 100E(X) - 75 \stackrel{\text{punkt A(iii)}}{=} 69,23... - 75 = -5,77... \approx -5,8$$

$$SD(U) = \sqrt{\text{var}(100X - 75)} \stackrel{\text{regel 4.15}}{=} \sqrt{100^2 \text{var}(X)} = 100 \cdot SD(X) \stackrel{\text{punkt B(iii)}}{=} 71,53... \approx 71,5$$

iii): Siden $V = -U$, får vi $E(V) = -E(U) = 5,8$ og

$SD(V) = \sqrt{\text{var}(-U)} = \sqrt{(-1)^2 \text{var}(U)} = SD(U) = 71,5$ (begge med en desimals nøyaktighet).

>>

- D.** La nå $V_{tot} = \sum_{i=1}^k V_i$ være total fortjeneste for tilbyderen etter k spill, der V_i er fortjenesten i spill nr. i . Vi antar V_1, V_2, \dots, V_k er uavhengige og identisk fordelte som V i punkt **C(iii)**.

- i)** Hvis $k \geq 20$, kan vi regne at V_{tot} er tilnærmet normalfordelt. Hvilken normalfordeling er aktuell som tilnærmelse? [Hint: Bestem a og b (uttrykt ved k) i uttrykket $V_{tot} \stackrel{\text{tilnærmet}}{\sim} N(a, b)$].
- ii)** Tilbyderen er interessert i sannsynligheten for at den totale fortjenesten blir negativ ($P(V_{tot} < 0)$) for forskjellige verdier av k . Bruk tilnærmelsen til normalfordelingen til å vise at $P(V_{tot} < 0) \approx G\left(-\sqrt{k} \cdot \frac{5,8}{71,5}\right)$, der $G(z) = P(Z \leq z)$ er den kumulative fordelingsfunksjonen for Z som er standard normalfordelt ($Z \sim N(0, 1)$). Forklar også hvorfor sannsynligheten $G\left(-\sqrt{k} \cdot \frac{5,8}{71,5}\right)$, som gjelder for en bestemt k , avtar når k øker.
- iii)** Beregn $P(V_{tot} < 0)$ tilnærmet når $k = 50$, $k = 500$ og $k = 1000$.

<< Svar: **i):** Siden $E(V_i) = E(V) = 5,8$ og $SD(V_i) = SD(V) = 71,5$, er det nok å vise til sentralgrensetoremet formulert i regel 5.19 som impliserer at

$$V_{tot} \stackrel{\text{tilnærmet}}{\sim} N(k \cdot E(V), \sqrt{k} \cdot SD(V)) = N(k \cdot 5,8, \sqrt{k} \cdot 71,5).$$

- ii):** Normaltilnærmelsen impliserer at $\frac{V_{tot} - k \cdot 5,8}{\sqrt{k} \cdot 71,5} \stackrel{\text{tilnærmet}}{\sim} N(0, 1)$. La $Z \sim N(0, 1)$.

Dermed

$$\begin{aligned} P(V_{tot} < 0) &= P\left(\frac{V_{tot} - k \cdot 5,8}{\sqrt{k} \cdot 71,5} < \frac{-k \cdot 5,8}{\sqrt{k} \cdot 71,5}\right) \approx P\left(Z < \frac{-k \cdot 5,8}{\sqrt{k} \cdot 71,5}\right) \xrightarrow{\text{kontinuerlig fordeling}} P\left(Z \leq \frac{-k \cdot 5,8}{\sqrt{k} \cdot 71,5}\right) \\ &= G\left(\frac{-k \cdot 5,8}{\sqrt{k} \cdot 71,5}\right) = G\left(-\sqrt{k} \cdot \frac{5,8}{71,5}\right) \end{aligned}$$

Hvis k øker, øker også \sqrt{k} slik at $-\sqrt{k} \cdot \frac{5,8}{71,5}$ øker. Siden $G(z)$ er strengt voksende i z ,

må dermed $G\left(-\sqrt{k} \cdot \frac{5,8}{71,5}\right)$ øke.

iii): Skriv kort $z_k = -\sqrt{k} \cdot \frac{5,8}{71,5}$. Siden $P(V_{tot} < 0) \approx G\left(-\sqrt{k} \cdot \frac{5,8}{71,5}\right) = G(z_k)$, får vi av tabell E3 i Løvås:

k	z_k	$G(z_k) \approx P(V_{tot} < 0)$
50	-0,57	0,2843
500	-1,81	0,0351
1000	-2,57	0,0051

>>

- E. Tilbyderen ønsker å bestemme en (tilnærmet) 95% sikker nedre grense for den totale fortjenesten, V_{tot} , når $k = 1000$ spill. Med andre ord, tilbyderen er ute etter en konstant, c , slik at $P(V_{tot} > c) \approx 0,95$ når $k = 1000$.

Bestem c ut fra normaltilnærmelsen for V_{tot} .

<< Svar:

$$\text{Vi har } P(V_{tot} > c) = 1 - P(V_{tot} \leq c) = 1 - P\left(\frac{V_{tot} - k \cdot 5,8}{\sqrt{k} \cdot 71,5} \leq \frac{c - k \cdot 5,8}{\sqrt{k} \cdot 71,5}\right) \approx 1 - G\left(\frac{c - k \cdot 5,8}{\sqrt{k} \cdot 71,5}\right).$$

Bestemmer vi c slik at det siste uttrykket blir lik 0,95, blir $P(V_{tot} > c) \approx 0,95$. Altså

$$\begin{aligned} 1 - G\left(\frac{c - k \cdot 5,8}{\sqrt{k} \cdot 71,5}\right) = 0,95 &\Leftrightarrow G\left(\frac{c - k \cdot 5,8}{\sqrt{k} \cdot 71,5}\right) = 0,05 &\Leftrightarrow \frac{c - k \cdot 5,8}{\sqrt{k} \cdot 71,5} = -1,645 &\Leftrightarrow \\ &\Leftrightarrow c = k \cdot 5,8 - (1,645)\sqrt{k} \cdot (71,5) \end{aligned}$$

$$\text{eller for } k = 1000: \quad c = 1000 \cdot 5,8 - (1,645)\sqrt{1000} \cdot (71,5) = 5800 - 3719,4 = 2080,6.$$

Tilbyderen kan således være tilnærmet 95% sikker på å få en fortjeneste på over 2080 kr ved $k = 1000$ spill.

(I parentes bemerket er forventet fortjeneste 5800 kr.)

>>

Oppgave 2

To meningsmålingsinstitutter, her kalt MM1 og MM2, foretar på samme tidspunkt, og uavhengig av hverandre, en måling av støtten i befolkningen for et parti vi kaller B. Målingene er basert på to rent tilfeldige utvalg av stemmeberettigete. Den relative andelen av populasjonen av stemmeberettigete som ville stemme på B på det aktuelle tidspunktet kaller vi p , som er ukjent, men som estimeres både av MM1 og MM2 basert på sine utvalg.

Andelen målt i prosent kaller vi μ der $\mu = 100p$. Det er vanlig å publisere resultater fra meningsmålinger som prosentandeler (dvs. som estimatorer på μ) istedenfor relative andeler (estimatorer på p). I denne oppgaven vil vi derfor se på μ som parameteren av primær interesse.

Utvalgstørrelsen til MM1 er $n_1 = 950$ og til MM2, $n_2 = 1055$. Begge utvalgene antas for enkelthets skyld i denne oppgaven som «rent tilfeldige», slik at alle mulige ikke-ordnede utvalg av stemmeberettigete har samme sannsynlighet for å bli valgt. Antallet som ville stemme på B i utvalg j (trukket av MM j) betegnes med X_j , for $j = 1, 2$.

Som modellantakelse antar vi at X_1 og X_2 er uavhengige og binomisk fordelte stokastiske variable med parametere (n_1, p) og (n_2, p) henholdsvis (skrevet kort: $X_j \sim \text{bin}(n_j, p)$, $j = 1, 2$), med samme p for $j = 1, 2$. Prosentanden i utvalg j som ville stemme på B betegnes med

$$Y_j = 100 \frac{X_j}{n_j}, \quad j = 1, 2. \quad Y_1 \text{ og } Y_2 \text{ vil da også være uavhengige stokastiske variable siden}$$

X_1, X_2 er det.

Resultatet av målingene er gitt i tabell 1:

Tabell 1

	MM1	MM2
Utvalgstørrelse n_j	950	1055
Antall B-stemmer X_j	217	258
Relativ andel av B \hat{p}_j	0.228	0.245
Prosentandel $Y_j \%$	22.8	24.5

- A. i) Drøft kort om antakelsen at X_j er binomisk fordelt er rimelig hvis utvalget (j) er rent tilfeldig.
ii) Vis at $\hat{\mu} = \bar{Y} = \frac{Y_1 + Y_2}{2}$ er forventningsrett som estimator for μ , og beregn estimatet for μ basert på $\hat{\mu}$. [Hint. Gjør bruk av sammenhengen, $Y_j = 100 \frac{X_j}{n_j}$, $j = 1, 2$.]

- iii) Vis at standardfeilen til $\hat{\mu}$ (dvs. standardavviket her) er

$$SE(\hat{\mu}) = 50 \cdot \sqrt{\left(\frac{1}{n_1} + \frac{1}{n_2} \right) \cdot p(1-p)}$$

[Hint: Vis først at $\text{var}(Y_j) = 100^2 \frac{p(1-p)}{n_j}$ for $j = 1, 2$]

<< **Svar:** **i):** Hvis utvalget er rent tilfeldig, er X_j hypergeometrisk fordelt som er tilnærmet binomisk (med $p = M/N$ = populasjonsandelen) hvis populasjonen er stor – som den åpenbart er i dette tilfellet.

ii): Siden $E(Y_j) = E\left(100 \frac{X_j}{n_j}\right) = 100 \frac{1}{n_j} E(X_j) = 100p = \mu$, blir

$$E(\hat{\mu}) = \frac{E(Y_1) + E(Y_2)}{2} = \frac{2\mu}{2} = \mu \text{ - dvs. } \hat{\mu} \text{ forventningsrett.}$$

Estimat: $\hat{\mu}_{obs} = \frac{22,8 + 24,5}{2} = 23,65 \%$.

iii): Ved regneregler for varians får vi:

$$\text{var}(Y_j) = \text{var}\left(100 \frac{X_j}{n_j}\right) = \frac{100^2}{n_j^2} \text{var}(X_j) = \frac{100^2}{n_j^2} n_j p(1-p) = \frac{100^2}{n_j} p(1-p)$$

hvorav, siden Y_1 og Y_2 er uavhengige,

$$\begin{aligned} \text{var}(\hat{\mu}) &= \text{var}\left(\frac{Y_1 + Y_2}{2}\right) = \frac{1}{4} (\text{var}(Y_1) + \text{var}(Y_2)) = \\ &= \frac{1}{4} \left(\frac{100^2}{n_1} p(1-p) + \frac{100^2}{n_2} p(1-p) \right) = \frac{100^2}{4} \left(\frac{1}{n_1} + \frac{1}{n_2} \right) p(1-p) \end{aligned}$$

som gir

$$SE(\hat{\mu}) = \sqrt{\text{var}(\hat{\mu})} = \frac{100}{2} \sqrt{\left(\frac{1}{n_1} + \frac{1}{n_2} \right) p(1-p)}$$

>>

B. **i)** Forklar, ved bruk av relevante regler, at $\hat{\mu}$ er tilnærmet normalfordelt,

$$\hat{\mu} \stackrel{\text{tilnærmet}}{\sim} N(\mu, SE(\hat{\mu})).$$

[Hint. Det kan være lurt å skrive $\hat{\mu}$ uttrykt ved X_1 og X_2]

ii) Innledning. MM1 og MM2 oppgir begge $\pm 2,6$ prosentpoeng som (95%) feilgrenser for sine anslag på μ , der begrepet «feilgrense» refererer til et tilnærmet 95% konfidensintervall for μ . Når tallene fra MM1 (eller fra MM2) settes inn i konfidensintervallet, får intervallet formen «(anslag på μ) $\pm 2,6$ » (som du ikke trenger å verifisere her), der $\pm 2,6$ ofte kalles feilgrenser. Det er grunn til å tro at feilgrensene blir mindre hvis vi kombinerer informasjonen fra de to målingene.

Spørsmål. Sett opp og beregn et tilnærmet 95% konfidensintervall for μ basert på punkt **B(i)**, og angi nye feilgrenser for estimatet $\hat{\mu}_{obs}$ basert på de kombinerte dataene fra MM1 og MM2.

[**Hint:** Du trenger et anslag på $SE(\hat{\mu})$ som avhenger av den ukjente p og er derfor ukjent. Som antydet under regel 6.8 og 6.12 i Løvås, kan den ukjente p erstattes med et estimat, \hat{p}_{obs} , (her f.eks. $\hat{\mu}_{obs}/100$, der indeksen obs indikerer at det er den observerte verdien som brukes) uten at konfidensgraden endres vesentlig (noe som kan vises i videregående teori)]

<< Svar:

i): Uttrykt ved X_1 og X_2 , blir $\hat{\mu} = \frac{Y_1 + Y_2}{2} = \frac{100 \frac{X_1}{n_1} + 100 \frac{X_2}{n_2}}{2} = \frac{50}{n_1} X_1 + \frac{50}{n_2} X_2$.

X_1 og X_2 er uavhengige og tilnærmet normalfordelte ifølge regel 5.20. Da må en lineær-kombinasjon som $\hat{\mu}$ ifølge regel 5.17 også være tilnærmet normalfordelt. Løvås er litt vag i regel 5.17 siden han ikke sier hvilken normalfordeling som er aktuell, men det framgår av eksempelet etter regel 5.17 at det er forventning og standardavvik til $\hat{\mu}$ som skal brukes som parametere. På forelesningene har vi vært noe mer presis om dette, men slett ikke alle har fulgt forelesningene...

Alternativt vil noen bruke regel 5.17 direkte på Y_1 og Y_2 som de vil argumentere er uavhengige og tilnærmet normalfordelte siden Y_j er en konstant ganger X_j . En slik løsning er selvsagt akseptabel også.

- ii): På grunn av punkt **i**) følger av regel 6.8 at et tilnærmet 95% konfidensintervall for μ er gitt ved $\hat{\mu} \pm (1,96)SE(\hat{\mu})$, der $1,96 = z_{0,025}$ er 0,025-kvantilen i $N(0, 1)$. Siden $SE(\hat{\mu})$ avhenger av den ukjente p , foreslår Løvås å erstatte p med et estimat, \hat{p}_{obs} , og antyder således implisitt at dette ikke ødelegger konfidensgraden vesentlig. Dette poenget er presistert noe mer i et supplerende forelesningsnotat om konfidensintervall på kurssiden på nettet. Det er flere estimer for p man kan bruke (f.eks. et av de to estimatene produsert av MM1 og MM2 som bør aksepteres om kandidaten foreslår det), men det mest naturlige er vel å benytte det intuitivt beste anslaget,
- $$\hat{p}_{obs} = \hat{\mu}_{obs}/100 = 23,65/100 = 0,2365$$

Med dette anslaget får vi estimert standardfeil:

$$SE(\hat{\mu}) \approx 50 \cdot \sqrt{\left(\frac{1}{n_1} + \frac{1}{n_2} \right) \cdot \hat{p}_{obs} (1 - \hat{p}_{obs})} = 50 \cdot \sqrt{\left(\frac{1}{950} + \frac{1}{1055} \right) \cdot 0,2365 \cdot (1 - 0,2365)} = 0,9503$$

som gir tilnærmet 95% feilgrenser

$$\pm (1,96)SE(\hat{\mu}) \approx \pm 1.8626 \approx \pm 1,9$$

Det tilsvarende konfidensintervallet for μ blir $23,7 \pm 1,9 = [21,8, 25,6]$

>>

- C. Innledning.** Valgbarometre publiseres med jamne mellomrom der resultater fra flere meningsmålingsinstitutter samles. Tabell 2 viser¹ prosentandeler for partiet Høyre målt av 9 meningsmålingsinstitutter i januar 2017.

Tabell 2 Prosentandeler for Høyre målt i januar 2017

i	1	2	3	4	5	6	7	8	9
Institutt	Ipsos/MMI	Opinion	Gallup	Sentio	Norstat	Respons	Infact	Norstat	Norfakta
%-andel Høyre (Y_i)	22,9	23,3	24,5	22,8	24,5	23,3	20,9	22,6	25,3

Deskriptive størrelser for tallene i tabell 2 er gitt i tabell 3 produsert av Excel:

Tabell 3 Excel deskriptive størrelser for dataene i tabell 2

Y	
Mean	23.34
Standard Error	0.4334
Median	23.3
Mode	23.3
Standard Deviation	1.3001
Sample Variance	1.6903
Kurtosis	0.5
Skewness	-0.3
Range	4.4
Minimum	20.9
Maximum	25.3
Sum	210.1
Count	9

Tallene i tabell 2 representerer 9 anslag på prosentandelen, μ , for Høyre i populasjonen av stemmeberettigete i Norge i januar 2017. Tallene kan betraktes som observasjoner av uavhengige stokastiske variable, Y_1, Y_2, K, Y_n , der $n = 9$. Utvalgsstørrelsene bruket av de forskjellige meningsmålingsinstituttene er ikke oppgitt i kilden, men ligger alle i

¹ **Kilde:** Bernt Aardals hjemmeside: <http://www.aardal.info/>

nærheten av 1000. Dette betyr at variansene til Y_i -ene, som egentlig ikke er helt like, på den annen side ikke varierer spesielt mye. For enkelthets skyld antar vi derfor i modellen at variansene er like uten vesentlig tap av realisme. Likeledes antar vi for enkelthets skyld i modellen at Y_i -ene er normalfordelte selv om de egentlig bare er tilnærmet normalfordelte.

Oppsummert: som **modell** antar vi at Y_1, Y_2, K, Y_9 er uavhengige og identisk normalfordelte med ukjent forventning μ og (konstant og ukjent) varians, σ^2 (skrevet kort: $Y_i \sim N(\mu, \sigma^2)$, $i = 1, 2, K, 9$).

Spørsmål:

- i) Estimer prosentandelen av stemmeberettigete i Norge som ville stemme på Høyre januar 2017 ved bruk av en forventningsrett estimator som utnytter informasjonen fra alle de 9 meningsmålingsinstituttene.
- ii) I oktober 2016 lå Høyres prosentandel på ca. 24,5%. Sett opp en test med signifikansnivå 5% for nullhypotesen $H_0: \mu \geq 24,5$ mot $H_1: \mu < 24,5$. Bruk tallene i tabell 3 til å gjennomføre testen og formuler en konklusjon.
- iii) Basert på tabellene i Løvås, er (a) p-verdien for testen i punkt ii) mindre enn 1%, (b) ligger den mellom 1% og 2,5%, (c) mellom 2,5% og 5% eller (d) er den større enn 5%? Begrunn svaret ditt.

<< Svar: i): Den foreslalte modellen for Y_1, Y_2, K, Y_9 er *uid* modellen som er relativt grundig behandlet i pensum, og der $\hat{\mu} = \bar{Y} = \frac{1}{9} \sum_{i=1}^9 Y_i$ er den foreslalte forventningsrette estimatoren. Tabell 3 gir estimatet $\hat{\mu}_{obs} = "mean" = 23,34$.

ii): Uid-modellen med 9 normalfordelte variable leder til en T-test for H_0 :

$$\text{Testobservator: } T = \frac{\bar{Y} - 24,5}{S} \sqrt{9}, \text{ der } S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2}.$$

T er $t(n-1) = t(8)$ fordelt hvis $\mu = 24,5$, og en 5% test for H_0 er gitt ved

Forkast H_0 hvis $T \leq -t_{8, 0,05} (= -1,86)$ (der $t_{8, 0,05}$ er 0,05-kvantilen i $t(8)$ -fordelingen)

Observert gir tabell 3, $S_{obs} = "standard deviation" = 1,3001$ og

$$T_{obs} = \frac{23,34 - 24,5}{1,3001} \sqrt{9} = -2,68 \text{ mot kritisk verdi } -1,86$$

Konklusjon: Forkast H_0 . Det er altså sterk evidens (nivå 5%) i data for at prosentandelen for Høyre i januar 2017 har sunket i forhold til nivået i oktober 2016.

iii): Siden p-verdien er det minste nivået som leder til forkastning, og nivå 5% leder til forkastning, følger at p-verdien er lavere enn 5%. De kritiske verdiene for nivå 2,5% og 1% er henholdsvis -2,306 og -2,896, slik at vi forkaster H_0 på 2,5% men ikke på 1%.

Dette betyr at p-verdien ligger mellom 1% og 2,5%.

>>

- D.** Vi vender nå tilbake til situasjonen i punkt **2A**. En alternativ estimator for μ som kunne vært brukt, er

$$\mu^* = 100 \frac{X_1 + X_2}{n_1 + n_2}$$

Det kan vises, som du ikke trenger å gjøre, at μ^* er en optimal estimator for μ i betydningen at den har minst varians blant alle forventningsrette estimatorer. Likevel viser det seg at når utvalgstørrelsene er nær 1000 som her, så er den foreslalte estimatoren, $\hat{\mu} = \bar{Y}$, nesten like god som μ^* i den forstand at $\hat{\mu}$ og μ^* har nesten samme standardfeil. Illustrer dette ved å beregne forholdet mellom standardfeilene

$$\frac{SE(\hat{\mu})}{SE(\mu^*)} = \sqrt{\frac{\text{var}(\hat{\mu})}{\text{var}(\mu^*)}}$$

<< **Svar:** Vi finner

$$\text{var}(\mu^*) = \frac{100^2}{(n_1 + n_2)^2} (\text{var}(X_1) + \text{var}(X_2)) = \frac{100^2}{(n_1 + n_2)^2} (n_1 p(1-p) + n_2 p(1-p)) = 100^2 \frac{p(1-p)}{n_1 + n_2}$$

hvorav

$$SE(\mu^*) = \sqrt{\text{var}(\mu^*)} = \frac{100}{\sqrt{n_1 + n_2}} \sqrt{p(1-p)}$$

og

$$\frac{SE(\hat{\mu})}{SE(\mu^*)} = \frac{50 \cdot \sqrt{\left(\frac{1}{n_1} + \frac{1}{n_2}\right) \cdot p(1-p)}}{\frac{100}{\sqrt{n_1 + n_2}} \sqrt{p(1-p)}} = \frac{1}{2} \sqrt{(n_1 + n_2) \left(\frac{1}{n_1} + \frac{1}{n_2}\right)} = 1,0014\dots$$

som betyr at $SE(\hat{\mu}) \approx SE(\mu^*)$

>>