

TENTAMEN I STATISTIKENS GRUNDER 2 2016-10-26

Skrivtid: 10.00-15.00

Godkända hjälpmedel: Miniräknare, språklexikon.

Tentamen består av fem uppgifter. För full poäng på en uppgift krävs tydliga, utförliga och väl motiverade lösningar.

Uppgift 1

Förklara kortfattat följande begrepp:

- Samplingfördelning
 - P-värde
 - Förklara tolkningen av ett 95%-igt konfidensintervall
- Förklara kortfattat följande begrepp och skillnaden mellan dem.
- Korrelation och kausalitet
 - Enkelt index och sammansatt index

Uppgift 2

En fastighetsinvestering överväger 3 olika investeringsalternativ - bygga lägenheter, kontor eller ett köpcentrum. Avkastningen (i tusentals kronor) för varje investering beror på den framtida populationsökningen i området vilken delas in i tre scenarion - långsamt, normalt eller snabbt växande population. Avkastningen redovisas i tabellen.

	Långsamt	Normalt	Snabbt
Lägenheter	-750	100	1500
Kontor	-2000	500	1000
Köpcentrum	150	300	750

- Vilket investeringsalternativ bör väljas enligt maximinkriteriet?
- Vilket investeringsalternativ bör väljas enligt Laplacekriteriet?
- Vilket investeringsalternativ bör väljas enligt maximaxkriteriet?
- Vilket investeringsalternativ bör väljas enligt minimax regretkriteriet?

Uppgift 3

Det påstås att Stockholmare är världens mest tatuerade storstadsfolk. I genomsnitt är 14% av världens storstadsinvånare (18-49 år) tatuerade. För att skatta andelen tatuerade stockholmare tog man ett slumpmässigt urval av 550 stockholmare i åldern 18-49 år, 182 av dessa var tatuerade.

- Uppskatta proportionen tatuerade stockholmare i åldern 18-49 år.
- Uppskatta variansen hos urvalsproportionen. Bör ändlighetskorrektion användas? Motivera.
- Gör ett 90 procentigt konfidensintervall för proportionen tatuerade stockholmare i åldern 18-49 år.
- Hur stort urval bör man dra om man önskar att längden på hela konfidensintervallet inte ska överstiga fem procentenheter?

Uppgift 4

Folkhälsomyndigheten rapporterar kontinuerligt andelen vuxna svenskar i fyra olika viktkategorier - undervikt (BMI <18.5), normalvikt (BMI 18.5-24.9), övervikt (BMI 25-29.9) och fetma (BMI >30). År 2000 var den procentuella viktfordelningen av Sveriges vuxna befolkning följande.

<i>Undervikt</i>	<i>Normalvikt</i>	<i>Övervikt</i>	<i>Fetma</i>
7%	49.5%	34%	9.5%

- 2014 gjordes en undersökning bland 600 slumpmässigt utvalda vuxna svenskar. Urvalets viktfordelning blev då följande.

<i>Undervikt</i>	<i>Normalvikt</i>	<i>Övervikt</i>	<i>Fetma</i>
2%	48.5%	35.5%	14%

Testa med lämpligt hypotestest om fördelningen över viktkategorierna 2014 är densamma som den var 2000. Använd signifikansnivån 1%.

- I 2014 års undersökning var 290 kvinnor och 310 män. Testa med lämpligt test om fördelningen mellan viktclasserna är samma för kvinnor och män. Använd signifikansnivån 1%.

	<i>Undervikt</i>	<i>Normalvikt</i>	<i>Övervikt</i>	<i>Fetma</i>	Antal
Kvinnor	9	157	84	40	290
Män	3	133	130	44	310

Uppgift 5

Det har gjorts 40 mätningar av mängden av ett visst tillsatsämne i en livsmedelsprodukt. Mätningarna betraktas som ett utfall av den stokastiska variabeln X med väntevärde μ och varians σ^2 . Vi antar att alla X är oberoende. Urvalsmedelvärdet blev 1.033 gram och urvalsvariansen 0.01188. Det rekommenderade nivån av tillsatsämnet i det aktuella livsmedlet är 1.0 gram. Vid tillverkningen av livsmedlet är det en maskin som proportionerar tillsatsämnet i varje enhet. Maskinen kan ställas in på önskad nivå (gram per enhet) men det blir alltid en mindre variation av mängden som tillsätts de olika enheterna.

a) Tyder data på att maskinen är inställd på en högre nivå än den rekommenderade? Utför ett lämpligt test och beräkna p-värdet, kommentera resultatet.

Vi tänker oss att vi har 40 andra mätningar Y_1, Y_2, \dots, Y_{40} från samma produktion. Dessa Y har samma väntevärde som X men osäkerheten i dessa mätningar är större vilket medför en varians för Y på $2.25\sigma^2$. Vi antar att alla Y är oberoende och att X och Y är oberoende. Två estimatorer för μ har föreslagits

$$\hat{\mu}_1 = \frac{1}{2}(\bar{X} + \bar{Y}) \quad \hat{\mu}_2 = \frac{2}{3}\bar{X} + \frac{1}{3}\bar{Y}$$

b) Visa att både $\hat{\mu}_1$ och $\hat{\mu}_2$ är väntevärdesriktiga. Räkna ut variansen för båda estimatorerna. Vilken av estimatorerna är den bästa? Motivera.

Statistiska institutionen



Stockholms
universitet

Rättningsblad

Datum: 26/10-2016

Sal: Värtasalen

Tenta: Statistikens grunder 2

Kurs: Statistikens grunder

ANONYMKOD:

SGR-0059

Jag godkänner att min tenta får läggas ut anonymt på hemsidan som studentsvar.

OBS! SKRIV ÄVEN PÅ BAKSIDAN AV SKRIVBLADEN

Markera besvarade uppgifter med kryss

1	2	3	4	5	6	7	8	9	Antal inl. blad
X	X	X	X	X					11
Lär.ant.	20	20	18,5	20	20				

POÄNG

98,5

BETYG

A

Lärarens sign.

G/F

Uppgift 4

Förklara kortfattat begrepp:

a) Samplingsfördelning beskriver hur urvalsmedelvärdet kommer att avvika i populationen, dvs om vi tar ett urval från en population och beräknar dess urvalsvärde (\bar{x}) och stand. avvikelse (s_x) och sedan beräknar urvalsmedelvärdets avvikelse $z_{\bar{x}}$ som $z_{\bar{x}} = \frac{s_x}{\sqrt{n}}$, där n är urvalsstorleken. Kommer dessa parametrar $(\bar{x}, \frac{s_x}{\sqrt{n}})$ beskriva samplingsfördelning för \bar{x} i populationen (om vi tar n stycken lika stora urval från samma population utifrån de parametrarnas spridningen för populationens medelvärde). (4)

b) P-värde: kan tolkas som:

- sannolikheten att få en lika stort extremvärde eller större som \bar{x} från våra observationer;
- den anger den lägsta sign. nivå på vilken vår h0-hypotes kan

förkastas. Om p -värdet är mindre än sign. nivå, då säger vi att våra observationerna är stat. signifikanta på sign. nivå större än p -värdet. Om p -värde är större än sign. nivå, då säger vi att våra observationer inte är stat. signifikanta och att H_0 inte kan förkastas på sign. nivå $\leq p$ -värdet. (4)

c) 95% -igt. k. i anger intervall som kan innehålla det sanna värdet på populationens medelvärde med 95% säkerhet. Dvs om vi drar n stycken lika stora urval från samma population kommer i 95 fall av 100 det sanna μ ligga i beräknade 95% -igt. konfidensintervall för detta urval. (4)

d) Korrelation visar hur starkt eller svagt samband finns mellan variablerna. Korrelationen kan vara positiv (om en variabel ökar i värde, så ökar den andra och vice versa), eller negativ (om en ökar, minskar den andra och vice versa). Korrelationen kan också vara 0, dvs vi kan inte påvisa en linjärt samband mellan variablerna.

Kausalslets visar ett orsaks samband mellan variablerna, dvs hur en variabel påverkar den andra (alltså i en riktning).

Om variablerna är korrelerade betyder det inte vara att det föreligger ett kausalt samband mellan dem. Det kan vara så att en tredje variabel som vi inte "ser" påverkar de andra och därför ger intryck att det kan finnas orsaks samband mellan två andra variabler, som är korrelerade.

Som regel måste man komma ihåg att en stark korrelation mellan variablerna är inte bevis för orsaks samband mellan dem. Om användar man ändå förnekt när man tolkar korrelationen och samband mellan variablerna.

c) Enkel index: $I_t^b = \frac{x_t}{x_0} \cdot 100$
 visar hur priser (etc) för en enhet (vara) i tidpunkt t har ändrats i jämförelse med basårspunkten.

Sammansatt index, t.ex. KPI, visar
hur priser (för en korg
av varor) har ändrats i
jämförelse med någon
given tidpunkt (för KPI
tidpunkten är ofta år 1980).

4

Uppgift 2

Handlingsalt (HA)	Tillstånd		
	långsamt	Normalt	Snabbt
HA ₁ - lägenhet	-450	100	1500
HA ₂ - kontor	-2000	500	1000
HA ₃ - köpcentrum	150	300	450

- a) Maximinkriteriet ("personligt kriteriet"): vi försöker gardera oss mot dåliga utfall, vi väljer den minsta nyttan för varje handlingsalternativ och sedan väljer det HA bland dem som ger den största nyttan.

$$a_{ij} = \frac{1}{3} a_i = -450, a_{2i} = -2000, a_{3i} = 150$$

Svar: en fastighetsinvestering bör byggas ett köpcentrum enligt maximinkriteriet. (5)

- b) Laplacekriteriet: vi antar att varje tillstånd, alltså varje scenario i vilket fall, har samma sannolikighet att hända ($p(\text{långsamt}) = p(\text{normalt}) = p(\text{snabbt}) = \frac{1}{3}$) och sedan räknar det förväntade värde för varje

handlingsalternativ. Vi väljer sedan det förväntade värdet som har den största nyttan (som för beslut under risk).

	Långs. ($\frac{1}{3}$)	Norm. ($\frac{1}{3}$)	Snabbt ($\frac{1}{3}$)	$E(U)$
U_L	-750	100	1500	283,33
U_K	-2000	500	1000	-166,67
U_{Kc}	150	300	750	400

$$E(U_L) = -750 \cdot \frac{1}{3} + 100 \cdot \frac{1}{3} + 1500 \cdot \frac{1}{3} = 283,33$$

$$E(U_K) = -2000 \cdot \frac{1}{3} + 500 \cdot \frac{1}{3} + 1000 \cdot \frac{1}{3} = -166,67$$

$$E(U_{Kc}) = 150 \cdot \frac{1}{3} + 300 \cdot \frac{1}{3} + 750 \cdot \frac{1}{3} = 400$$

Svar: en fastighetsinvestorare bör bygga ett köpcentrum enligt Laplacekriteriet. (5)

d) maximaxkriteriet ("optimistisk kriteriet")
vi väljer den största nyttan för varje handlingsalternativ och sedan väljer den största bland dem.

$$a_{i,j} = \max \{ a_{i1} = 1500, a_{i2} = 1000, a_{i3} = 750 \}$$

Svar: en fastighetsinvestorare bör bygga köpcentrum enligt maximaxkriteriet. (5)

d) Minimaxkriteriet: vi försöker minimera "ångern" med minmax-regret-kriteriet. Vår max alternativ förlusten bör vara så liten som möjligt. Alt. förlusten räknas enligt följande:

$$r_{ij} = S_{ij} - u_{ij}, \text{ där}$$

S_{ij} - den maximala nyttan för varje tillstånd. I vårt fall:

$$S_k(\text{max}) = 150, S_N(\text{max}) = 500, S_s(\text{max}) = 1500$$

Regretmatrix

	S_k	S_N	S_s
K_{A_k}	$150 + 750 = 900$	$500 - 100 = 400$	$1500 - 1500 = 0$
K_{A_N}	$150 + 2000 = 2150$	$500 - 500 = 0$	$1500 - 1000 = 500$
K_{A_s}	$150 - 150 = 0$	$500 - 300 = 200$	$1500 - 750 = 750$

$$r_{ij} = \{r_k = 900, r_k = 2150, r_{kl} = 750\}$$

Svar: fastighetshuset bör bygga köpcentrum enligt minmax-regret-kriteriet.

(5)

Uppgift 13

Urval: $n = 550$ (pers, stockholmare), 18-49 år,
182 av dessa är tatuerade.

a) Proportionen tatuerade stockholmare
i åldern 18-49 år:

$$p = \frac{182}{550} \approx 0,331 \quad (\approx 33,1\%) \quad (2)$$

Svar: proportionen tatuerade stockholmare
i åldern 18-49 år är cirka 33,1%
($p \approx 0,331$).

b) Variansen hos urvalsproportionen.
Ändlighetskorrektionen?

Vi gör urval ($n = 550$) utan återläggning
för att skatta proportionen tatuerade
stockholmare från populationen

"stockholmare" som omfattar personer
i åldern 18-49 år. Åldersspridningen
i populationen är tillräckligt stor och
omfattar såväl unga som medelåldriga
personer i arbetsföra åldern, dvs
populationen kan sägas vara
oändlig, dvs ändlighetskorrektionen
behöver inte användas.

Variansen kan räknas utligt följande
formelt: $V(p) = \frac{p(1-p)}{n}$ såsom för
urval med återläggning (oberoende
fördeliger).

Vidare $n = 550$ (stort, > 30), $np = 550 \cdot 0,331 =$
 $= 182,05$ samt $n(1-p) = 550 \cdot 0,669 =$
 $= 367,95$ (> 5), där fördelning
 för proportionen kan approxi-
 meras med normalfördelning
 enligt CGS.

$$\Rightarrow V(p) = \frac{p(1-p)}{n} = \frac{0,331 \cdot 0,669}{550} =$$


$$= \frac{0,221439}{550} \approx 0,000403$$

Svar: variansen hos urvalsproportionen
 är lik med c. 0,000403. ändlighets-
 korrekturen bör inte användas
 eftersom vi gör urval från en
 oändlig population. (3)

Ne, antal stockholmare är ändligt

c) 90%-igt k.i.: fördelningen för
 proportionen turade stockholmare
 kan approximeras med normal-
 fördelning enligt CGS (mer utförlig
 motivering i punkt (b)), 90%-igt k.i.
 kan därför beräknas enligt följande:

$$p \pm Z_{0,05} \cdot \sqrt{\frac{p(1-p)}{n}} \quad / \quad \text{JK N(91)}$$



Ur tabellen för n.f. i:

$$z_{0,05} = 1,6449$$

$$\sqrt{\frac{p(1-p)}{n}} = \sqrt{0,000403} \approx 0,02007$$

Felmarginalen $B = 1,6449 \cdot 0,02007 \approx 0,033$

$$p \pm B$$

$$0,331 \pm 0,033$$

$$[0,298, 0,364]$$

§

Svar: 90%igt konfidensintervall för vårt urval är $[0,298, 0,364]$, vilket betyder att i 90 fall av 100 kommer det sanna värdet för proportionen ligga i intervallet $[0,298, 0,364]$ (eller $[29,8\%, 36,4\%]$).

d) $n = ?$, $2B = 5\%$.

$$2B = 0,05 \rightarrow B = \underline{0,025}$$

Formeln: $1,6449 \cdot \sqrt{\frac{p(1-p)}{n}} \leq B$

$$1,6449^2 \cdot \frac{p(1-p)}{n} \leq B^2$$

$$n \cdot B^2 \geq 1,6449^2 \cdot p \cdot (1-p)$$

$$n \geq \frac{1,6449^2 \cdot p(1-p)}{B^2}$$

Alternativt: $p = 0,331 \Rightarrow$

$$n \geq \frac{1,6449^2 \cdot 0,331 \cdot 0,669}{(0,025)^2} \geq \frac{0,5991}{0,000625} \geq 958,56 \checkmark$$

$n \geq 1296$

Eller, alternativ 2: där $p = 0,5$ (ger den största variansen).

$$n \geq \frac{1,6449^2 \cdot 0,5 \cdot 0,5}{(0,025)^2} \geq \frac{0,676424}{0,000625} \geq 1089,88 \checkmark$$

$n \geq 1463$

Svar: Man bör dra minst a) $n = 1296$ (urvalsvariansen skattas med $p = 0,331$), eller b) $n = 1463$ (urvalsvariansen antas som maximal $(0,25)$ med $p = 0,5$).

5,5

Uppgift 4

Vår info

Undervikt: $BMI < 18,5$

Normalvikt: $18,5 < BMI < 24,9$

Övervikt: $25 < BMI < 29,9$

Fetma: $BMI > 30$

År 2000, fördelning

Undervikt	Norm.	Övervikt	Fetma
7%	49,5%	34%	9,5%

a) År 2014, undersökning bland 600 vuxna svenskar ($n = 600$).

År 2014, fördelning:

Undervikt	Norm.	Övervikt	Fetma
2%	48,5%	35,5%	14%

Testa med lämpligt nyttötest om fördelningen över vikt-kategorier 2014 är densamma som den var 2000, med

$$\alpha = 0,01$$

lösning: Eftersom data som vi disponerar är på ordinalskala så använder vi i det här fallet χ^2 -mätlet för att lösa uppgiften och antar att observationerna på vikt är st. oberoende.

Det lämpligt test i detta fall är "goodness of fit" test som testar om en viss stokastisk variabel

följer en viss fördelning, vilket fall om fördelningen över vikt-kategorierna år 2014 är densamma som den var år 2000.

Nullhypoteser: H_0 : fördelningen över vikt-kategorierna 2014 är densamma som den var år 2000.

H_1 : fördelningen - " - " - " - " skiljer sig från fördelningen år 2000.

Om $n = 600$ kommer vår fördelning år 2014 och den förväntade fördelningen över vikt-kategorierna given att H_0 stämmer ser ut som i tabell nedan:

i	$n_i(2014)$	$E(n_i)_{H_0} = n \cdot p_i$ <small>H_0 är sann</small>
Undervikt	$600 \cdot 0,02 = 12$	$600 \cdot 0,04 = 24$
Normalvikt	$600 \cdot 0,485 = 291$	$600 \cdot 0,495 = 297$
Övervikt	$600 \cdot 0,355 = 213$	$600 \cdot 0,34 = 204$
Fetma	$600 \cdot 0,14 = 84$	$600 \cdot 0,095 = 57$
Σ	600	600

Kritiskt värde: $SN = 10\%$, $\alpha = 0,01$.

$$\chi^2_{\alpha, df}(n-1) = \chi^2_{0,01}(4-1) = \\ = \chi^2_{0,01}(3) = 11,345 \text{ K}$$

Beslutsregel: vi förkastar H_0 om $\chi^2_{obs} > \chi^2_{0,01}(3) = 11,345$ på $SN 10\%$. K

Testvariabel:

$$\chi^2 = \sum \frac{(n_i - E(n_i))^2}{E(n_i)} \sim \chi^2(n-1)$$

$$\chi^2_{obs} = \frac{(72-42)^2}{42} + \frac{(291-297)^2}{297} + \frac{(213-204)^2}{204} + \\ + \frac{(84-54)^2}{54} = 21,43 + 0,12 + 0,397 + \\ + 12,49 = 34,737 \text{ K}$$

Svar: $\chi^2_{obs} = 34,737 > \chi^2_{0,01} = 11,345$, dvs vi kan förkasta nollhypotesen på sign. nivå 10%. Det finns alltså med stöd att fördelningen över viktkategorierna 2014 inte är densamma som den var år 2000. Testet som används är "goodness of fit test".

10

Förel. uppgift 4.

b) år 2014, $n = 600$, av dem 290 kvinnor och 310 män.

Är fördelningen mellan viktclasser är samma för kvinnor och män?

Lösning: vi har data på nominal/ordinalskala, därför använder vi χ^2 -mätter för att genomföra testet. I detta fall använder vi oss av "homogenitetestet" som sätter om två eller flera variabler kommer från samma fördelningen. $E(n_i) \geq 5$

2014	Kvinnor	Män	Σ	Prop.	Förväntade frekvenser	Kvinnor	Män	Σ
Undervikt	9	3	12	$\frac{12}{600}$		$\frac{12}{600} \cdot 290 = 5,8$	$\frac{12}{600} \cdot 310 = 6,2$	12
Normalv.	157	133	290	$\frac{290}{600}$		$\frac{290}{600} \cdot 290 = 140,17$	$\frac{290}{600} \cdot 310 = 149,83$	290
Övervikt	84	130	214	$\frac{214}{600}$		$\frac{214}{600} \cdot 290 = 103,43$	$\frac{214}{600} \cdot 310 = 110,57$	214
Fetma	40	44	84	$\frac{84}{600}$		$\frac{84}{600} \cdot 290 = 40,6$	$\frac{84}{600} \cdot 310 = 43,4$	84
Σ	290	310	600	1	Σ	290	310	600

Hypoteser: H_0 : Fördelningen mellan viktclasserna är samma för kvinnor och män.

H_A : — " — " — " — " är inte samma (stämmer sig).

Om det är så fördelningen "vikt klasser" är samma för kvinnor och män, då borde proportionen "underverkstiga" personer bli samma för kvinnor och män, i vårt fall $\frac{12}{600} = 0,02$ (dler 2%). Det betyder 5,8 kvinnor ($0,02 \cdot 290 = 5,8$) och 6,2 män ($0,02 \cdot 310 = 6,2$). På samma sätt beräknar vi de andra förväntade frekvenser (se tabell i början av uppgiften).

Testvariabel: $\chi^2 = \sum \frac{(n_i - E(n_i))^2}{E(n_i)} \sim \chi^2(\nu)$,

där $\nu = (\text{antal kategorier} - 1) \times (\text{antal populationer} - 1)$.

Kritiskt värde: $\alpha = 0,01$

$\chi_{0,01}^2 (4-1) \cdot (2-1) = \chi_{0,01}^2 (3) = 11,345$

Beslutsregeln: förkasta H_0 om $\chi_{obs}^2 > \chi_{0,01}^2 (3) = 11,345$.

$$\begin{aligned} \chi_{obs}^2 &= \frac{(9 - 5,8)^2}{5,8} + \frac{(3 - 6,2)^2}{6,2} + \frac{(154 - 140,17)^2}{140,17} + \\ &+ \frac{(133 - 149,83)^2}{149,83} + \frac{(84 - 103,43)^2}{103,43} + \frac{(130 - 119,57)^2}{119,57} + \\ &+ \frac{(40 - 40,9)^2}{40,9} + \frac{(44 - 43,4)^2}{43,4} = 1,47 + 1,65 + 2,02 + \\ &+ 1,89 + 3,65 + 3,41 + 0,009 + 0,008 \approx 14,408 \end{aligned}$$

Fört Upp 4, B

Svar: $\chi^2_{obs} = 14,408 > \chi^2_{0,01}(3) = 11,345$; des
 Mo förkastas på sign nivå 1%.
 Det betyder att vi har bevis för
 att fördelningen mellan vikt klasser
 inte är samma för kvinnor och
 män

(10)

Uppgift 5

a) Data: $n = 40$ mätningar. X -st. variabel
 (μ, σ²),
 X är oberoende.

$$\bar{x} = 1,033 \text{ g}$$

$$s_{\bar{x}}^2 = 0,0188$$

Rekommenderade nivå: 1,0 g.

Vi vet att X är en stok. variabel och
 att alla X är oberoende. Vi vet ej vilken
 fördelning X följer, och σ^2 är okänd.
 Men eftersom vårt urval ($n = 40$) är
 tillräckligt stort (> 30), kan vi
 approximera fördelningen till normal-
 fördelning och använda Z -variabeln
 som teststatistika

Hypoteser:


$$H_0: \mu = 1,0$$

$$H_A: \mu > 1,0 \quad (\text{ensidig test})$$

(Vi sätter $\mu > 1,0$ för H_A för att kolla om maskinen är inställd på högre nivå än rekommenderade 1,0 g.)

Testvariabel: $Z = \frac{\bar{x} - \mu_0}{s/\sqrt{n}} \stackrel{\text{opp}}{\sim} N(0,1)$ om H_0 är sann.

$$Z_{\text{obs}} = \frac{1,033 - 1,0}{\sqrt{0,0188/40}} = \frac{0,033}{0,0172357} \approx 1,91 \quad R$$



$$\begin{aligned} p\text{-värdet} &= P(Z > 1,91) = 1 - P(Z < 1,91) = \\ &= 1 - 0,97193 = 0,028 \quad R \end{aligned}$$

Svar: P-värdet = 0,028 eller 2,8%, vilket betyder att vi kan förkasta H_0 på alla sign. nivå som är större än p-värdet. T.ex. H_0 kan förkastas på sign. nivå 30%, 50%.. (dvs vår resultat i ett sådant fall kan sägas vara statistiskt signifikant). Men på alla nivå som är mindre än 2,8% kan vi inte förkasta H_0 . T.ex. om vi i välför

utföra testet på sign. nivå 10%, då kan vi inte förkasta H_0 (vår resultat kan inte sägas vara statistiskt signifikant) Det är för läsaren att utgöra vilken sign. nivå hen behöver för att tolka testet. I det här kan man säga att c. 28 av 1000 mätningar kommer att visa en högre nivå än den rekommenderade

(10)

b) $n = 40$ mätningar på Y (y_1, y_2, \dots, y_{40})

$$E(Y) = E(X)$$

$$V(Y) = 2,25 \cdot 3^2$$

$$\hat{\mu}_1 = \frac{1}{2}(\bar{X} + \bar{Y})$$

$$\hat{\mu}_2 = \frac{2}{3}\bar{X} + \frac{1}{3}\bar{Y}$$

(c) Visa att $\hat{\mu}_1$ och $\hat{\mu}_2$ är väntevärdesuttryck

a) $\hat{\mu}_1$

$$\begin{aligned} E(\hat{\mu}_1) &= E\left(\frac{1}{2}(\bar{X} + \bar{Y})\right) = \frac{1}{2}E(\bar{X} + \bar{Y}) = \\ &= \frac{1}{2}(E(\bar{X}) + E(\bar{Y})) = \frac{1}{2}\left(E\left(\frac{\sum_{i=1}^n X_i}{n}\right) + E\left(\frac{\sum_{i=1}^n Y_i}{n}\right)\right) = \\ &= \frac{1}{2}\left(\frac{1}{n} \cdot E(n \cdot X_i) + \frac{1}{n} \cdot E(n \cdot Y_i)\right) = \\ &= \frac{1}{2}\left(\frac{n}{n} \cdot E(X_i) + \frac{n}{n} \cdot E(Y_i)\right) = \frac{1}{2}(E(X) + E(Y)) = \\ &= \frac{1}{2} \cdot 2\mu = \mu. \end{aligned}$$

I vårt fall $E(\bar{X}) = 1,033$, $E(\bar{Y}) = E(Y) =$
" $\mu = 1,033$, på samma sätt

$$E(Y) = E(\bar{Y}) = 1,033.$$

$$\rightarrow E(\hat{\mu}_1) = \frac{1}{2}(1,033 + 1,033) = 1,033$$

$$(2) \hat{\mu}_2 = \frac{2}{3}\bar{X} + \frac{1}{3}\bar{Y}$$

$$E(\hat{\mu}_2) = E\left(\frac{2}{3}\bar{X} + \frac{1}{3}\bar{Y}\right) = \frac{2}{3}E(\bar{X}) + \frac{1}{3}E(\bar{Y}) =$$

$$= \frac{2}{3} \cdot \frac{E(nX_i)}{n} + \frac{1}{3} \frac{E(nY_i)}{n} = \frac{2}{3} \cdot \frac{n \cdot E(X)}{n} +$$
$$+ \frac{1}{3} \cdot \frac{n \cdot E(Y)}{n} = \frac{2}{3}E(X) + \frac{1}{3}E(Y) = E(X)$$

$$= \frac{2}{3}E(X) + \frac{1}{3}E(Y) = E(X) = \mu$$

I vårt fall $E(\bar{X}) = 1,033$, $E(\bar{Y}) = E(Y) =$
 $= 1,033$, $E(Y) = 1,033$.

$$\rightarrow E(\hat{\mu}_2) = \frac{2}{3} \cdot E(\bar{X}) + \frac{1}{3} \cdot E(\bar{Y}) =$$

$$= \frac{1}{3} \cdot 1,033 + \frac{2}{3} \cdot 1,033 = \underline{1,033}$$

Svar: Vi har visat att både $\hat{\mu}_1$ och $\hat{\mu}_2$ är i var genom att visa att $E(\hat{\mu}_1) = E(\hat{\mu}_2) = \mu$ och i vårt fall $E(\hat{\mu}_1) = E(\hat{\mu}_2) = 1,033$.

(ii) Räkna ut varianserna för $\hat{\mu}_1$ och $\hat{\mu}_2$.

$$\begin{aligned} V(\hat{\mu}_1) &= V\left(\frac{1}{2}(\bar{X} + \bar{Y})\right) = \frac{1}{4} V(\bar{X} + \bar{Y}) = \\ &= \frac{1}{4} (V(\bar{X}) + V(\bar{Y})) = \frac{1}{4} \left(\frac{V(X)}{n} + \frac{V(Y)}{n}\right) \quad (n=40) \\ &= \frac{1}{4} \left(\frac{3^2}{40} + \frac{2,25 \cdot 3^2}{40}\right) = \frac{1}{4} \cdot \frac{3,25 \cdot 3^2}{40} = \\ &= \frac{3,25 \cdot 3^2}{160} \approx 0,0203 \cdot 3^2 \quad \text{K} \end{aligned}$$

$$\begin{aligned} V(\hat{\mu}_2) &= V\left(\frac{2}{3}\bar{X} + \frac{1}{3}\bar{Y}\right) = \frac{4}{9} V(\bar{X}) + \frac{1}{9} V(\bar{Y}) = \\ &= \frac{4}{9} \cdot \frac{3^2}{n} + \frac{1}{9} \cdot \frac{2,25 \cdot 3^2}{n} = \frac{4 \cdot 3^2}{9 \cdot 40} + \frac{2,25 \cdot 3^2}{9 \cdot 40} = \\ &= \frac{6,25 \cdot 3^2}{360} = 0,0173 \cdot 3^2 \quad \text{K} \end{aligned}$$

Om vi skattar σ^2 med S_x^2 (både X och Y kan approx. med n.f. då n är stort),
får vi: $V(\hat{\mu}_1) = 0,0203 \cdot 3^2 = 0,0203 \cdot S_x^2 =$

$$= 0,0203 \cdot 0,01188 \approx 0,000241$$

$$V(\hat{\mu}_2) = 0,0173 \cdot 3^2 = 0,0173 \cdot S_x^2 =$$

$$= 0,0173 \cdot 0,01188 \approx 0,000206$$

Svar: Varianserna för både estimatorerna
är: $V(\hat{\mu}_1) \approx 0,0203 \cdot 3^2$ (eller i kortare
fall $V(\hat{\mu}_1) = 0,000241$) och $V(\hat{\mu}_2) = 0,0173 \cdot 3^2$,

eller i vårt fall $V(\hat{\mu}_2) = 0,000206$.

(iii) Vilken av estimatorerna är bästa?

Svar: den bästa estimatorn är den som har minst varians, dvs spridningen kring kring väntevärdet är mindre. För att välja den bästa estimatorn måste vi i så fall välja den minsta variansen bland.

$$V(\hat{\mu}_1) = 0,0203 \cdot \sigma^2$$

$$V(\hat{\mu}_2) = 0,0173 \cdot \sigma^2$$

$V(\hat{\mu}_2) < V(\hat{\mu}_1)$, eftersom $0,0173 < 0,0203$, vad också skrivas om vi sätter σ^2 med $S^2 = 0,0188$:

$$V(\hat{\mu}_1) = 0,0203 \cdot 0,0188 = 0,000381$$

$$V(\hat{\mu}_2) = 0,0173 \cdot 0,0188 = 0,000205$$

Vi kan se att $V(\hat{\mu}_2)$ är något mindre än $V(\hat{\mu}_1)$.

Svar: den bästa estimatorn är

$\hat{\mu}_2 = \frac{2}{3}\bar{x} + \frac{1}{3}y$, då den har mindre varians.

10

Statistiska institutionen



Stockholms
universitet

Rättningsblad

Datum: 26/10-2016

Sal: Värtasalen

Tenta: Statistikens grunder 2

Kurs: Statistikens grunder

ANONYMKOD:

SGD-0055

Jag godkänner att min tenta får läggas ut anonymt på hemsidan som studentsvar.

OBS! SKRIV ÄVEN PÅ BAKSIDAN AV SKRIVBLADEN

Markera besvarade uppgifter med kryss

1	2	3	4	5	6	7	8	9	Antal inl. blad
X	X	X	X	X					9
Lär.ant.	19	20	20	17					

POÄNG	BETYG	Lärarens sign.
96	A	JF

HS

urvals-karakteristiken

- ① a) Samplingfördelning är fördelningen av ^{urvals-karakteristiken} observationerna, en urvalsundersökning kring medelvärdet \bar{X} , dvs värdet på de olika observationerna och hur många observationer som gjorts på de olika värdena.
- b) P-värdet är sannolikheten att få ett värde i i en urvalsundersökning som är lika sannolikt eller mindre sannolikt än det erhållna värdet förutsatt att populationsmedelvärdet är sant. Om man gör en hypotesprövning och beräknar exempelvis Z_{obs} är p-värdet sannolikheten att få ett värde på Z_{obs} som är lika eller mindre sannolikt än det erhållna värdet givet att H_0 är sann. Storleken på p-värdet kan alltså användas för att testa hur troligt det är att en hypotes kan förkastas. Ett mycket litet p-värde gör att H_0 kan förkastas. Hur litet det ska vara beror på vilken signifikansnivå man väljer. Ju mindre p-värde desto större signifikansnivå. Om p-värdet är stort har vi fått ett värde som är sannolikt och vi kan inte förkasta H_0 .

↓
forts:
a)

Samplingfördelningen är motsvarigheten till den teoretiska sannolikhetsfördelningen för hur utfall kommer att fördelas i teorin.

④

③

c)

En 95% -igt konfidensintervall ger värdet som om man gör en stor mängd urvalsundersökningar så kommer urvalsmedelvärdet att ligga inom gränserna för konfidensintervallet i 95% av fallen. 15% av fallen kommer värdet att ligga utanför intervallet för ett visst populationsmedelvärde, (eller proportion).

4

d)

Korrelation betyder att det finns ett ^{linjärt} samband mellan två variabler. Tex om den ena ökar så ökar den andra också, eller om den ena ökar så minskar den andra. Det betyder dock inte betydligt att orsaken att den ena ökar är den andra variabeln. Det kan lika gärna vara en tredje variabel som gör att de båda variablerna ökar samtidigt tex.

Ex. i samhällen där det finns många storkar föds det många barn, men storkarna är inte orsaken till att det föds fler barn, det är att det finns fler storkar och det föds fler barn i små orter.

Kausalitet är att det finns ett orsakssamband mellan två variabler. Den ena variabelns förändring orsakas av den andra. Det är inte alltid lätt att avgöra om det finns kausalitet mellan två variabler.

Id forts.

Man måste visa att förändringen inte skett om det inte hade varit för variabelns påverkan, och att det finns en tidsmässig ordning, påverkan skedd före verkan.

4

e) Ett enkelt index visar förändringen i tid för en variabel, tex pris över tid, förhållande till ett basvärde. Det visar alltså procentuell förändring över tid från en basårspunkt.

Ett sammansatt index väger samman flera olika variabler, tex priser på flera olika varor. Ex KPI som väger samman en mycket stor mängd konsumentprodukter, varor och tjänster, för att visa hur den allmänna prisstämningen har förändrats över tid. I sammansatta index brukar man använda viktade värden där vikterna kan vara produktivitet eller försäljning, så att varor som är vanligare får större vikt i indexet. Exempel på sammansatta index är Laspeyres index och Paasches index.

4

② En fasthetsinvesterare överväger 3 olika investeringsalternativ: lägenheter, kontor eller köpcentrum.

Handlingsalt.	Naturtillstånd			Maximin $\min(a_{1j}, a_{2j}, a_{3j})$	Maximax $\max(a_{1j}, a_{2j}, a_{3j})$
	S_1 Långsamt	S_2 Normalt	S_3 Snabbt		
A_1 Lägenheter	-750	100	1500	-750	1500
A_2 Kontor	-2000	500	1000	-2000	1000
A_3 Köpcentrum	150	300	750	150	750

a) Max, min kriteriet: Investeraren väljer det största värdet av de minsta avkastningsalternativen, dvs alternativ 3 - köpcentret som ger den lägsta avkastningen 150 tkr.

Svar: Alternativet köpcentrum väljs.

⑤

b) Laplace kriteriet. Man antar att alla alternativ är lika sannolika, dvs $\frac{1}{3}$ sannolikhet var beträffande naturtillstånden långsamt, normalt och snabbt växande population. Sedan väljs det största väntevärdet. Laplace: $\max(E(u_1), E(u_2), E(u_3))$

A_1 Lägenheter	$\frac{1}{3}(-750) + \frac{1}{3} \cdot 100 + \frac{1}{3} \cdot 1500 = 283,3$
A_2 Kontor	$\frac{1}{3}(-2000) + \frac{1}{3} \cdot 500 + \frac{1}{3} \cdot 1000 = -166,67$
A_3 Köpcentrum	$\frac{1}{3} \cdot 150 + \frac{1}{3} \cdot 300 + \frac{1}{3} \cdot 750 = 400$

Vänd \rightarrow

b)

Svar: Enligt Laplacekriteriet väljs alternativ 3, Köpcentrum, där avkastningen förväntas bli 400 tkr.

(5)

c)

Enligt maximaxkriteriet jämförs de största avkastningarna för varje naturtillstånd och så väljs det alternativ som har den största avkastningen.

Svar: Alternativ 1, Lägerheter väljs enligt maximaxkriteriet med en avkastning på 1500 tkr.

(5)

d) Minimax regret: alternativet som ger den minsta "ängern" väljs. Skillnaden mellan det största värdet och värdet för varje naturtillstånd beräknas och det högsta värdet för varje handlingsoption jämförs. Det minsta värdet av dessa väljs.

$$S_1^+ = 150 \quad S_2^+ = 500 \quad S_3^+ = 1500$$

	Lägstvärde $S_1^+ = 150$	Normalt $S_2^+ = 500$	Högstvärde $S_3^+ = 1500$	
A ₁ Lägerheter	$150 - (-750) = 900$	$500 - 100 = 400$	$1500 - 1500 = 0$	900
A ₂ Kontor	$150 - (-2000) = 2150$	$500 - 500 = 0$	$1500 - 1000 = 500$	2150
A ₃ Köpcentrum	$150 - 150 = 0$	$500 - 300 = 200$	$1500 - 750 = 750$	750

Svar d: Enligt minimax regret väljs alternativ 3, Köpcentrum, som har det minsta värdet för den största "ängern".

(5)

③

Uppställa andelen tatuerade Stockholmare, 18-49 år

Urvalsundersökning gjordes med $n = 550$. Av dessa

var 182 tatuerade. Anta att observationen är oberoende och likafördelad

a) proportionen som är tatuerad uppskattas med

$$p = \frac{\sum_{i=1}^n X_i}{n} \quad \text{där } X_i = 1 \text{ om personen är tatuerad och } X_i = 0 \text{ om personen inte är tatuerad.}$$

$$p = \frac{182}{550} = 0,3309$$

X är stokastiskt oberoende variabler.

b)

Svar: Proportionen tatuerade Stockholmare är 33,09%

Variansen hos urvalsproportionen är:

$$S_p^2 = \frac{p(1-p)}{n} = \frac{0,3309(1-0,3309)}{550} = 0,000402$$

Ändlighetskorrektur behöver inte användas eftersom N är så stort. N är populationen, dvs alla Stockholmare mellan 18 och 49 år, flera hundra tusen.

Ändlighetskorrektionen $\frac{N-n}{N-1}$ går mot 1 när N

är stort. Sin regel brukar man inte behöva använda ändlighetskorrektur när den är $> 0,95$.

Här:

$$\frac{N-550}{N-1} = 0,95 \Leftrightarrow N-550 = 0,95(N-1) \Leftrightarrow$$

$$N-550 = 0,95N - 0,95 \Rightarrow N = 10981$$

$$0,05N = 549$$

Så för N över ca 11000 behövs inte ändlighetskorrektur.

och, det här fallet är N betydligt större.

Värd \rightarrow

Svar: Variansen för urvalsproportionen är 0,0004
om ändlighetskorrektion behövs inte eftersom
N är så stort.

4

c)

Konfidensintervall för proportioner

$$p \pm z_{\alpha/2} \sqrt{\frac{p(1-p)}{n}}$$

Eftersom n är så stort och $p \cdot n = 0,33 \cdot 550 = 181,5$
och $(1-p)n = 368,5$ båda är större än 5

kan vi approximera fördelningen med
normalfördelningen enligt centrala gränsvärdesatsen.

90% -igt konfidensintervall $\Rightarrow \alpha = 0,1$

$$\alpha/2 = 0,05$$

$$z_{\alpha/2} = z_{0,05} = 1,6449 \quad \text{ur tabell 2}$$

$$p = 0,3309$$

konfidensintervall blir:

$$0,3309 \pm \sqrt{\frac{0,3309(1-0,3309)}{550}} \cdot 1,6449$$

$$0,3309 \pm 1,6449 \cdot 0,02006 \Rightarrow$$

$$0,3309 \pm 0,033$$

Svar Ett 90% -igt konfidensintervall ges av

$$0,3309 \pm 0,033 \quad \text{eller} \quad [0,2979; 0,3639]$$

8

③ Forts

d) Hur stort urval? Hitta n

Längden på hela konfidensintervallet ska vara

max. 5 procentenheter dvs 0,05

Halva konfidensintervallet = 0,025

Halva konfidensintervallet = Felmarginalen = B

ses av

$$B = z_{\alpha/2} \sqrt{\frac{p(1-p)}{n}} \Rightarrow$$

$$0,025 = 1,6449 \sqrt{\frac{0,3309(1-0,3309)}{n}}$$

$$\left(\frac{0,025}{1,6449}\right)^2 = \frac{0,3309(1-0,3309)}{n}$$


$$2,3099 \cdot 10^{-4} = \frac{0,2214}{n}$$

$$n = 958,49$$

$$\Rightarrow n = 959$$

man avrundar alltid
uppåt för att säkerställa
att konfidensintervallet
ska bli max 5% -enteter.

Svar $n = 959$ st



③

4

Andelen vuxna svenskar i BMI-kategorier:

	hela populationen	urval	
	2000	2014	$\alpha = 0,01$
Undervikt	0,07	0,02	$n = 600$
Normalvikt	0,495	0,485	
Övervikt	0,34	0,355	
Fetma	0,095	0,14	

Testa om fördelningen över vikt-kategorierna är samma. Vi använder ett goodness-of-fit-test med χ^2 för att avgöra om fördelningen i urvalsundersökningen överensstämmer med populationens fördelning.

Antal	2000	2014
Undervikt	42	12
Normalvikt	297	291
Övervikt	204	213
Fetma	57	84

I den första kolumnen är de förväntade värdena om den teoretiska fördelningen stämmer, dvs $0,07 \cdot 600 = 42$ personer bör vara underviktiga i urvalet osv. Alla värden är > 5 så vi kan gå vidare utan att slå ihop klasser.

Vi sätter upp en hypotes:

H_0 : Fördelningen i urvalsundersökningen ²⁰¹⁴ är samma som populationsfördelningen 2000. \checkmark

H_A : Fördelningen i urvalsundersökningen 2014 är inte samma som 2000.

För både H_0 och H_A gäller en signifikansnivå på 0,01.

Vi antar att urvalsundersökningen gjorts på lika fördelade oberoende stickprov.

Vi förkastar H_0 om $\chi_{obs} > \chi_{0,01}(v)$

där $v = \text{frihetsgrader} = (\text{antal klasser} - 1) = 4 - 1 = 3$

$$\chi_{obs} = \sum_{i=1}^K \frac{(E(n_i) - n_i)^2}{E(n_i)} \quad \chi_{0,01}(3) = 11,345 \quad \checkmark$$

$K = \text{antal klasser}$

$$\begin{aligned} \chi_{obs} &= \frac{(42 - 12)^2}{42} + \frac{(297 - 291)^2}{297} + \frac{(204 - 213)^2}{204} \\ &\quad + \frac{(57 - 84)^2}{57} = 34,736 \quad \checkmark \end{aligned}$$

$$\chi_{obs} = 34,736 > 11,345 = \chi_{0,01}(3)$$

H_0 kan förkastas.

Svar H_0 kan förkastas på signifikansnivån 1%.

detta fördelningarna är inte lika 2014 som 2000.

10

4 b)

	Kvinnor	Män	
Undervikt	9	3	12
Normalvikt	157	133	290
Övervikt	84	130	214
Fetma	40	44	84
	290	310	600

Vi vill testa om fördelningen mellan män och kvinnor är samma mellan de olika BMI-kategorierna.

Det gör vi med ett homogenitetstest med χ^2

Vi beräknar fördelningen för det totala urvalet och jämför det med fördelningen för kvinnor och män.

Vi gör en tabell över de förväntade värdena

	Kvinnor $E(n_{i.})$	Män $E(n_{.j})$
Undervikt)	$\frac{12}{600} \cdot 290 = 5,8$	$\frac{12}{600} \cdot 310 = 6,2$
Normalvikt)	$\frac{290}{600} \cdot 290 = 140,17$	$\frac{290}{600} \cdot 310 = 149,83$
Övervikt)	$\frac{214}{600} \cdot 290 = 103,43$	$\frac{214}{600} \cdot 310 = 110,57$
Fetma	$\frac{84}{600} \cdot 290 = 40,6$	$\frac{84}{600} \cdot 310 = 43,4$

Alla värden på de förväntade antalet är större än 5.

Vi sätter upp hypotesen:

H_0 : Fördelningen mellan de olika BMI-kategorierna är lika för män och kvinnor

H_A : Fördelningen är inte lika.

Testvariabel $\chi^2_{obs} = \sum_{\substack{\text{alla} \\ \text{celler}}} \frac{(E(n_i) - n_i)^2}{E(n_i)}$

$$\chi^2_{krit} = \chi^2_{0,01} (\text{antal rader} - 1)(\text{antal kolumner} - 1) =$$

$$\chi^2_{0,01} (2-1)(4-1) = \chi^2_{0,01} (3) = 11,345$$

Vi förkastar H_0 om $\chi^2_{obs} > \chi^2_{0,01}(3) = 11,345$

$$\chi^2_{obs} = \frac{(5,8-9)^2}{5,8} + \frac{(140,17-157)^2}{140,17} + \frac{(103,43-84)^2}{103,43}$$

$$+ \frac{(40,6-40)^2}{40,6} + \frac{(62-3)^2}{62} + \frac{(149,83-133)^2}{149,83} +$$

$$\frac{(110,57-130)^2}{110,57} + \frac{(43,4-44)^2}{43,4} =$$

$$1,7655 + 3,02075 + 3,65005 + 0,008866945$$

$$+ 1,65161 + 1,890469 + 3,414352 + 0,0082949 = 14,411$$

$$(14,40989753)$$

$$\chi^2_{obs} = 14,41 > 11,345 = \chi^2_{0,01}(3) \Rightarrow H_0 \text{ förkastas}$$

Svar. H_0 förkastas på signifikansnivån 1%.

detta fördelningarna är inte lika.

10

5

$$n=40$$

X - stokastisk variabel med väntevärde μ och
varians σ^2 X är oberoende.

$$\bar{x} = 1,033 \text{ g}$$

$$s_x^2 = 0,01188$$

Rekommenderad nivå $\mu_0 = 1,0$ gram

a) Tyder data på att maskinen är inställd på en högre
nivå än den rekommenderade.

Hypotes:

$$H_0: \mu = 1,0 \text{ gram} \quad \checkmark$$

$$H_1: \mu > 1,0 \text{ gram} \quad \text{ensidigt test}$$

Testvariabel: $Z = \frac{\bar{X} - \mu_0}{s_x / \sqrt{n}}$ där $Z \sim N(0,1)$
om H_0 är sann.

Vi kan använda oss av normalfördelningen eftersom
är så stort, så det spelar ingen roll vilken fördelning
 X kommer i form enligt centrala gränsvärdesatsen
 $X \sim N(\mu, \sigma^2)$

Vi kan förkasta H_0 om $Z_{obs} > Z_{0,05} = 1,6449$

Vi sätter $\alpha = 0,05$ tills vidare.

$$Z_{obs} = \frac{1,033 - 1}{\sqrt{0,01188}/\sqrt{40}} = 1,9149 \quad \checkmark$$

$1,9149 > 1,6449$ Vi kan förkasta H_0

på signifikansnivå 0,05, dvs det finns bevis för
att H_0 att $\mu > 1$.

Vänd =

Vi vill veta p-värdet

p-värdet är signifikansnivån vid det observerade värdet på $Z_{\text{obs}} = 1,9149$

Vi tittar i tabellen och får $z = 1,9149 \Rightarrow P(Z \leq z) = 0,97139$

p-värdet blir då $1 - 0,97139 = 0,0286$

Det är alltså sannolikheten att få ett värde på 1,9149 eller större om H_0 är sann.

Så på signifikansnivå 5% kan vi förkasta H_0 men inte på signifikansnivå 1%.

Så om vi vill förkasta hypotesen att $\mu = 1$ och slå fast att vi tror att $\mu > 1$ bör vi vara säkra vi vill vara, dvs vilken signifikansnivå vi väljer.

10

Svar a) Data tyder på att maskinen är inställd på en högre nivå, i alla fall om man säger sig med en signifikansnivå på $\alpha = 0,05$.

5b)

$n = 40$

 $Y =$ vikt av ämnet, oberoende

$\mu = 15$

$\sigma_Y^2 = 2,25\sigma^2$

 X och Y är oberoende.

$\hat{M}_1 = \frac{1}{2}(X + Y)$

$\hat{M}_2 = \frac{2}{3}X + \frac{1}{3}Y$

$E(\bar{X}) = \mu \quad E(Y) = E(\bar{X}) = \mu$

$E(\hat{M}_1) = E\left(\frac{1}{2}(X + Y)\right) = \frac{1}{2} \cdot E(X + Y) =$

$\frac{1}{2} (E(\bar{X}) + E(Y)) = \frac{1}{2} (\mu + \mu) = \frac{1}{2} 2\mu = \mu$

$E(\hat{M}_2) = E\left(\frac{2}{3}X + \frac{1}{3}Y\right) = E\left(\frac{2}{3}\bar{X}\right) + E\left(\frac{1}{3}Y\right) =$

$\frac{2}{3} \cdot E(\bar{X}) + \frac{1}{3} E(Y) = \frac{2}{3} \mu + \frac{1}{3} \mu = \frac{2\mu + \mu}{3} =$

$\frac{3\mu}{3} = \mu$

$\Rightarrow \hat{M}_1$ och \hat{M}_2 är båda väntevärdesriktiga,
v.s.v.

Variansen

$V(\hat{M}_1) = V\left(\frac{1}{2}(X + Y)\right) = \left(\frac{1}{2}\right)^2 \cdot V(X + Y) =$

$\frac{1}{4} (V(\bar{X}) + V(Y)) = \frac{1}{4} (\sigma^2 + 2,25\sigma^2)$

$= \frac{1}{4} \cdot (3,25\sigma^2) = \frac{3,25\sigma^2}{4} = 0,8125\sigma^2$

$$V(\hat{\mu}_2) = V\left(\frac{2}{3}\bar{X} + \frac{1}{3}\bar{Y}\right) = V\left(\frac{2}{3}\bar{X}\right) + V\left(\frac{1}{3}\bar{Y}\right) =$$

$$\left(\frac{2}{3}\right)^2 V(\bar{X}) + \left(\frac{1}{3}\right)^2 V(\bar{Y}) = \frac{4}{9} V(\bar{X}) + \frac{1}{9} V(\bar{Y}) =$$

$$\frac{4}{9} \sigma^2 + \frac{1}{9} 2,25 \sigma^2 = \frac{4\sigma^2 + 2,25\sigma^2}{9} = \frac{6,25\sigma^2}{9}$$

$$= 0,694 \sigma^2$$

Variansten var $\hat{\mu}_1$ är $0,8125\sigma^2$ och variansten
för $\hat{\mu}_2$ är $0,694\sigma^2$.

Svar Den bästa estimatören är $\hat{\mu}_2$. Båda
estimatorerna är väntevärdesriktiga men
 $\hat{\mu}_2$ har mindre varians vilket är bra.

7