

STOCKHOLMS UNIVERSITET

Statistiska institutionen

Jessica Franzén

## TENTAMEN I STATISTIKENS GRUNDER 2

2017-10-26

Skrivtid: 15.00-20.00

Godkända hjälpmmedel: Miniräknare.

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

### Uppgift 1

- Förklara vad som menas med en samplingfördelning. Ge exempel.
- Man utgår från ett givet konfidensintervall. Om sedan stickprovsstorleken  $n$  ökar samt konfidensgraden ökar, allt annat lika, kan man då veta vad som händer med längden på konfidensintervallet? Motivera.
- Förklara begreppet "styrka" i ett hypotestest.
- Hitta på två variabler som du tror är korrelerade och där det också finns ett kausalt samband. Hitta sedan på två nya variabler som du tror är korrelerade men där ett kausalt samband saknas. Försök att förklara hur du tänker.
- Om kovariansen mellan  $X$  och  $Y$  är negativ, vilken av  $V(X + Y)$  och  $V(X - Y)$  blir då störst? Motivera.

### Uppgift 2

Ett större företag vill undersöka bland sina anställda om det finns något intresse för att gå över till flextid. Ett slumpmässigt urval av 200 anställda tillfrågades och resultaten visas i tabellen.

	Män	Kvinnor
Positiv till flextid	50	90
Negativ till flextid	30	30

- Är inställningen till flextid beroende av kön? Utför ett lämpligt test och använd signifikansnivån 2,5 procent.
- Är andelen som är positiva till flextid bland företagets alla anställda större än 0.65? Testa med lämpligt test. Ange testets p-värde och diskutera resultatet.

### Uppgift 3

Man vill jämföra studenternas kunskaper i statistik efter två likvärdiga grundkurser i statistik vid två olika universitet. Antal kursdeltagare är över 500 vid båda universiteten. En månad efter avslutad grundkurs läter man 25 slumpmässigt utvalda studenter från respektive universitet göra samma statistiktest. Testet består av 7 uppgifter där varje uppgift ger maximalt 1 poäng. Maxpoängen på testet är med andra ord 7 poäng. Poängmedelvärde och standardavvikelse på testet uträknat från de 25 studenterna vid respektive universitet framgår i tabellen nedan.

Universitet A Universitet B

$$\bar{x} = 3.51 \quad \bar{x} = 3.92$$
$$s = 0.94 \quad s = 0.85$$

- a) Baserat på testresultaten, är studenternas kunskapsnivå i statistik högre bland studenterna på universitet B än bland studenterna på universitet A? Utför ett lämpligt test på signifikansnivån 0.05. Redogör för nödvändiga antaganden för att kunna utföra testet.
- b) Beräkna två 95%-iga konfidensintervall för medelpoängen på testet, ett för respektive universitet.

### Uppgift 4

Antal liter efterfrågad mjölk per vecka producerade av mejeriet Skogskossan är normalfördelad med väntevärde 56 000 liter och standardavvikelse 5500 liter. Mejeriet Skogskossan klassificerar den veckovisa efterfrågan som "Låg" (0-50 000 liter), "Medel" (50 000-62 000 liter) eller "Hög" (62 000 liter och mer).

- a) Räkna ut sannolikheterna för Låg, Medel och Hög efterfrågan av mejeriet Skogskossans mjölk.
- b) Mejeriet Skogskossan överväger vilken produktionsvolym som är den bästa. De kan lägga sin produktionsvolym på 40, 50 eller 60 tusen liter mjölk per vecka. Veckovinsten (tusentals kronor) vid olika produktionsvolym och efterfrågenivåer framgår av tabellen nedan. Hjälp Skogskossan att avgöra lämplig produktionsvolym genom att använda tabellen och resultatet i a).

		Efterfrågan		
		Låg (0-50000 liter)	Medel (50000-62000 liter)	Hög (62000 liter och mer)
Produktionsvolym	40	20	20	20
	50	15	35	35
	60	0	30	100

- c) För ett annat mejeri, Skogskalven, har man under det gångna årets 52 veckor registrerat antal liter efterfrågad mjölk per vecka uppdelad i de tre kategorinerna "Låg" (0-50 000 liter), "Medel" (50 000-62 000 liter) eller "Hög" (62 000 liter och mer). Antal veckor med Låg, Medel respektive Hög efterfrågan framgår av tabellen nedan. Testa med lämpligt test om fördelningen över Skogskalvens efterfrågan det gångna året är densamma som Skogskossans fördelning som räknades ut i a). Använd signifikansnivån 2.5%.

	Låg	Medel	Hög	Totalt
Antal veckor	5	39	8	52

**Uppgift 5**

Vi har en  $\chi^2$ -fordelad variabel, närmare bestämt  $X \sim \chi^2(10)$ . Väntevärde och varians för en  $\chi^2$ -fordelad variabel är  $\mu = v$  och  $\sigma^2 = 2v$  där  $v$  är antal frihetsgrader. Vidare har vi en normalfordelad variabel, närmare bestämt  $Y \sim N(5, 2^2)$ .  $X$  och  $Y$  är oberoende.

- a) Ange ungefärligt  $P(X > 4)$ .
- b) Man tar ett stickprov från  $\chi^2$ -fordelningen ovan där  $n = 40$ . Beräkna  $P(\bar{X} > 4)$ . Jämför resultaten i a) och b). Är det någon skillnad i resultat?, förklara varför eller varför inte och rita en skiss över aktuella fördelningar.
- c) Bestäm hur stort  $n$  minst måste vara för att  $P(\bar{X} > 11) < 0.01$ .
- d) Bestäm väntevärde och varians för  $K = 2X + 5Y$ .

## Rättningsblad

**Datum:** 26/10/17

**Sal:** Värtasalen

**Tenta:** Statistikens grunder 2

**Kurs:** Statistikens grunder 2

**ANONYMKOD:**

SG-0008

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 lln. blad
X	X	X	X	X					4 2
Lär.ant. 20	20	17	19	15					

POÄNG	BETYG	Lärarens sign.
91	A	GJF

# SU, STATISTIK

Skrivsal: Västasalen

Anonymkod: S6-0008

Blad nr: 1

Uppg. 1

- a) En samplingfördelning är en sannolikhetsfördelning för urvalskedjekluster istället då dessa kan ses som skickliga variabler. Exempel på urvalskedjekluster är som kan vara samplingfördelade iif urvalskedjans samt urvalsvarians. Här dessa fördelningar ser vi beror på de värden som erhålls i urvalet.

(7)

- b) Nej, det kan man inte. Om man sticker provstoralet  $n$ , minskar man bredden på konfidensintervallet. Om man däremot ökar  $n$ , ökar bredden istället broaden på konfidensintervallat. Med andra ord ger dessa motsatta effekter. För att veta var som händer med längden/bredden på konfidensintervallet måste man se vilkena för dessa handlingar.

(4)

- c) Att testens styrka betecknas  $1-\beta$  här är för sannolikheten att acceptera nollhypotesen till att denna är falsk. Man eftersträvar höga värden för testens styrka, dvs. låga värden på  $\beta$  (som anter värden mellan  $\alpha$  och  $1-\beta$ ).

Teststyrka:  $1-\beta = -P(H_0 \text{ accepteras} | H_0 \text{ falsk})$

(4)

- d) Två variabler som är korrelerade är inkonst och konsumtion. Som dessurum är ett kausalt samband (avseende-samband) då variabeln inkonst har en direkt påverkan på variabeln konsumtion. Dvs. om en förändring i inkonst kommer även en förändring i konsumtion upptäckas.

Två variabler som är korrelerade är trycket i en hundas ögon leks varje dag grivts en brudgömmhund medan den solnas. Det syns dock ett kausalt samband i att korrelationen snarare beror på att mätvärdena är tagna från samma hund.

(4)

- e)  $V(X-Y)$  blir störst då beroende råder och

$V(X-Y) = V(X) + V(Y) - 2\text{Cov}(X, Y)$  kommer att resultera i att den sista termen blir positiv medan det för  $V(X+Y) = V(X) + V(Y) + 2\text{Cov}(X, Y)$  kommer resultera i att den sista termen blir negativ. Detta gäller pga:

$-(-)++$  och  $+(-)=-$   $V(X-Y)$  blir då störst!

(4)

## Uppg 2. a) Oberoende test

Observerade frekvenser			Förväntade frekvenser				
Män	Kvinnor		Män	Kvinnor			
Positiv	50	90	140	Positiv	56	84	140
Negativ	30	30	60	Negativ	24	36	60
	80	120	200		80	120	200

$H_0$ : oberoende röster mellan inställning i HN flextid och kön  
 $H_A$ : Beroende röster mellan inställning i HN flextid och kön

Testvariabel: Då alla förväntade frekvenser  $E(n) \geq 5$  gäller

$$\chi^2 = \sum \frac{(n - E(n))^2}{E(n)} \sim \chi^2(v) \text{ om } H_0 \text{ är sann, där } v = (\text{antal kategorier} - 1)(\text{antal röster} - 1).$$

Kritiskt värde:  $\chi^2_{0,05}(1) = 3,84$  ✓ dvs i detta fall  $v=1$

Beslutssregel: Förkasta  $H_0$  om  $\chi^2_{\text{obs}} \geq \chi^2_{0,05}(1) = 3,84$

$$\chi^2_{\text{obs}} = \frac{(50-56)^2}{56} + \frac{(90-84)^2}{84} + \frac{(30-24)^2}{24} + \frac{(30-36)^2}{36} = 3,57$$

Svar:  $H_0$  kan inte förkastas på signifikansnivå 2,5 procent då (1)

$$\chi^2_{\text{obs}} = 3,57 < 3,84 = \chi^2_{0,05}(1). \text{ Dvs. det ger inte att bevisbeteckning.}$$

b)  $p$  = "antelen positiva HN flexid i urvalet"

$\pi$  = "andelen positiva HN flexid bland förtagets anställda"

$$p = \frac{50+90}{200} = \frac{140}{200} = 0,7$$

$$n(p) \geq 5$$

$H_0: \pi = 0,65$  Testvariabel:

Då urvalet är stort ( $n \geq 30$ ) upptäcks en normalfördelning enligt CLTS dvs.

$$H_A: \pi > 0,65 \quad Z = \frac{p - \pi}{\sqrt{\pi(1-\pi)/n}} \sim \text{approx } N(0,1) \text{ om } H_0 \text{ är sann.}$$

Högsideftest med signifikansnivån 5% ger beslutssregeln:

$H_0$  förkastas om  $Z_{\text{obs}} > Z_{0,05} = 1,6449$ .

→ Forts.

Uppg. 2 b) Forts.

$$Z_{\text{obs}} = \frac{0,7 - 0,65}{\sqrt{\frac{0,15 + 0,35}{200}}} \approx 1,4825 \quad \text{V}$$

$H_0$  förkunfts inte på signifikansnivå 5%  
 dvs;  $Z_{\text{obs}} = 1,4825 < 1,6449 \approx Z_{0,05}$ .

p-värde:  $P(Z \geq Z_{\text{obs}}) = P(Z \geq 1,48) = 1 - P(Z \leq 1,48) = 0,06944$  L

$$Z_{\text{obs}} = 1,4825 \approx 1,48$$

Svar: Testets p-värde är 0,06944, dvs den läggda signifikansnivån som  $H_0$  kan förkunfts på. Detta gör i linje med resultaten som jag erhöll när jag testade hypotesen på signifikansnivå 5% och inte kunde förversta  $H_0$ . Detta pga att man förverstar  $H_0$  på alla signifikansnivåer större än det p-värde vi räknat ut. Man kan dock inte den förversta hypotesen på 10% signifikansnivå. I stället drar man acceptern  $H_0$  på alla signifikansnivåer lägre än p-värdet. Man måste där för acceptera  $H_0$  inte förversta,  $H_0$  på 5% signifikansnivå vilket också resultatet från testet jag utlade visade!

Uppg. 3.

a)  $A =$  "kunstuppsnivå Universitet A"  
 $B =$  "kunstuppsnivå Universitet B"

$$n_A = n_B = 25$$

$$\frac{N-n}{N-1} = \frac{50-25}{50-1} =$$

$$\approx 0,952$$

dvs hz. nte  
med! **U**

$$H_0: M_A = M_B$$

$$H_A: M_A < M_B$$

Antagande:

Vi vidtar att göra oberoende observationer.  
Normalförd pop.

Urvalssstorleken är inte stor ( $n_A=25$  och  $n_B=25$ ) men  
de sifferna sätter värdet för  $t_{0,05}(48)$  ~~minst~~  
normalapproximation ~~avvärnings~~. Därför  
 $t_{0,05}(50)$  (som finns i tabell) visar på samma resultat  
(att  $H_0$  inte verifieras på sign.nivn 5%).  
resulteren rimliga.

Testvariabel:

~~t-försl~~  $t = \frac{\bar{x}_A - \bar{x}_B - D_0}{\sqrt{\frac{s_A^2}{n_A} + \frac{s_B^2}{n_B}}} \sim N(0, 1)$  om  $H_0$  är sann.

Beslutsregel:

Förvara  $H_0$  om  $|t_{obs}| \geq t_{0,05} = -1,6449$

$$t_{obs} = \frac{3,51 - 3,92 - 0}{\sqrt{\frac{0,94^2}{25} + \frac{0,85^2}{25}}} \approx -1,6176$$

Svar:  $H_0$  fört kassas inte på signifikansnivn 5%  
då  $|t_{obs}| = -1,6176 \geq -1,6449 = t_{0,05}$ . Dvs kan  
vi inte beröra att kunstuppsnivån är högre  
 bland studenter vid universitet B.

Först förlor (so) gettare

$$t_{obs} = \frac{\bar{x}_A - \bar{x}_B - D_0}{\sqrt{\frac{s_A^2}{n_A} + \frac{s_B^2}{n_B}}} \quad \text{K}$$

Antagande:  
beroende ibz

Förvara  $H_0$  om  $|t_{obs}| \geq 1,676$

N-förd pop.

$$|t_{obs}| = \frac{3,51 - 3,92 - 0}{\sqrt{0,80305(\frac{1}{25} + \frac{1}{25})}} \approx 1,618 \quad \text{K}$$

$$\sigma^2 = \sigma_A^2 + \sigma_B^2$$

R

$H_0$  förlorats!

7

SU, STATISTIK

Skrivsal: Värtasalen

Anonymkod: SG-0008

Blad nr: 3

Uppg. 3. b)

Universitet A

Överstaende obs  
samt N. förd  
populärhet  
antalet för  
de båda  
universiteten

$$\bar{x} \pm t_{0,025}(24) \cdot \frac{0,51}{\sqrt{25}}$$

$$3,51 \pm 2,064 \cdot \frac{0,51}{\sqrt{25}}$$

$$3,51 \pm 0,388032$$

$$[3,121968; 3,898032]$$

Svar: Ett 95% konf. för  
medelpoängen på testet för  
Universitet A är  
[3,121968; 3,898032] ✓

Universitet B

$$3,92 \pm t_{0,025}(24) \cdot \frac{0,85}{\sqrt{25}}$$

$$3,92 \pm 0,35088$$

$$[3,56912; 4,27088]$$

Svar: Ett 95% konf. i.  
för medelpoängen på  
testet för Universitet B  
är

$$[3,56912; 4,27088]$$

(10)

$$\text{Uppg. 4. a)} P(\text{låg effektiviteten}) = P(X < 50000) = P(Z < \frac{50000 - 55000}{5500}) =$$

$$x = \text{"låg effektivitet"} = P(Z < -1,09) = 1 - \Phi(-1,09) = 1 - \Phi(1,09) = 0,13786$$

$$E(X) = 50000 \quad P(\text{medel effektiviteten}) = P(50000 < X < 62000) =$$

$$\sigma_X = 5500 \quad = P\left(\frac{50000 - 55000}{5500} < Z < \frac{62000 - 55000}{5500}\right) = P(-1,09 < Z < 1,09) =$$

$$x = \Phi(1,09) - \Phi(-1,09) = 1 - \Phi(-1,09) = 0,72428$$

$$P(\text{hög effektiviteten}) = P(X > 62000) = P(Z > \frac{62000 - 55000}{5500}) =$$

$$= 1 - \Phi(1,09) = 0,13786$$

$$P(\text{Låg effektivitet}) + P(\text{medel effektivitet}) + P(\text{Hög effektivitet}) = 1$$

(3)

Uppg. 4 b) Beslut under risk  
Eftersättning

	Lag	Medel	Hög	Förväntad myxa
	p=0,13786	p=0,72713	p=0,03498	
Produktionsvolym	40	20	20	20
	50	15	35	35
(60)	0	30	100	70

Svar: Största förväntade myxan för vissa  
produktionsvolymen är 60 kusen liter mjölk  
per vecka. Detta är det lämpligt att välja  
denna alternativ.

c) Goodness-of-fit test.

	n	E(n)
L	5	7,16872
M	39	37,66256
H	8	7,16872
	52	

Alla  $E(n_i) \geq 5$  sätter  
approx 0,01

$H_0$ : Fördelningen för skogsbearbetning  
eftertragen följer den  
skogsklassan. dvs 0,13, 0,72

$H_A$ : Fördelningen för skogsbearbetning  
eftertragen följer inte den  
för skogsklassan.

Teststatibel:

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

om  $n_i$  är sann.

$$k-1 = 3-1 = 2$$

Beslutssregel:

$$\text{förlästa } H_0 \text{ om } \chi^2_{n_i} \geq \chi^2_{0,025}(2) = 7,378 \text{ V}$$

$$\chi^2_{n_i} = \frac{(5-7,16872)^2}{7,16872} + \frac{(39-37,66256)^2}{37,66256} + \frac{(8-7,16872)^2}{7,16872} \approx 0,800 \text{ V}$$

Svar:  $H_0$  kan inte förvaras på signifikansnivå  
2,5% dvs  $\chi^2_{0,025} = 9,801 < 7,378 = \chi^2_{0,025}(2)$

8

# SU, STATISTIK

Skrivsal: Värtasalen

Anonymkod: S6-0008

Blad nr: 4

$$\text{Uppg. 5. } \mu = 10 \quad \sigma^2 = 20 \quad \sigma = \sqrt{20} = 2\sqrt{5}$$

$$\text{a) } P(X > 4) = P\left(Z > \frac{4-10}{2\sqrt{5}}\right) = P(Z > -1,34) = \\ = 1 - P(Z < -1,34) = 1 - \Phi(-1,34) = 1 - (1 - \Phi(1,34)) = \\ = \Phi(1,34) = 0,90988 \quad \text{Svars: } P(X > 4) = 0,90988 \quad (5)$$

$$\text{b) } P(X > 4) = P\left(Z > \frac{4-10}{\sqrt{20}}\right) = P(Z > -1,41) = \\ = 1 - P(Z < -1,41) = 1 - (1 - \Phi(-1,41)) = \Phi(1,41) \approx 1$$


*Svar:* Det är sannolikhet i resultatet då vi ser att

vi får ett urval med en värde större än 4;

i urval om 40 är nästan 1 medan vih

är först vitt på X större än 4 är  
0,9. Detta är inte konstigt då man vid  
enstaka mätningar kan få en större varians,  
i detta fall  $\sigma^2=20$  än vid mätningar  
med större urval; i detta fall  $\sigma^2=\frac{20}{40}$ . Med  
andra ord ger detta att variansen  
på varandra vi förflyttar vi drar ut  
urval av mindre än de som vi får när

vi drar enstaka mätningar; detta  
visas i skisserna nedan!




$$P(X > 4)$$

$$\sigma^2 = 20$$



(6)

$$\sigma^2 = \frac{20}{40}$$



Uppg: 5.

c)  $P(\bar{x} > 1) = P\left(Z > \frac{1 - 10}{\sqrt{\frac{20}{n}}}\right) = P\left(Z > \frac{1}{\sqrt{\frac{20}{n}}}\right)$

$P(Z = 2,3263) = 0,01$

$P(Z > 2,3263) < 0,01$

$Z > 2,3263$

$Z > \frac{1}{\sqrt{\frac{20}{n}}}$

$2,3263 = \frac{1}{\sqrt{\frac{20}{n}}}$

$\frac{1}{2,3263} = \sqrt{\frac{20}{n}}$

$0,429867171 = \frac{1,472135955}{\sqrt{n}}$

$\sqrt{n} = 10,40352987$

$n \approx 108,23$  avrunda uppåt dvs  
 $(n \geq 109)$

Svar:  $n$  måste vara minst 109 ( $n \geq 109$ ) för att  $P(\bar{x} > 1) < 0,01$

d)  $E(K) = E(2X + 5Y) = 2E(X) + 5E(Y) =$   
 $= 2 \cdot M_x + 5 \cdot M_y = 2 \cdot 10 + 5 \cdot 5 = 20 + 25 = 45$  kr

~~Det är en del av uppg 4~~  
 $V(K) = V(2X + 5Y) = 2^2 V(X) + 5^2 V(Y) =$   
 $= 4V(X) + 25V(Y) = 4 \cdot (2 \cdot 20) + 25 \cdot (2^2) =$   
 $= 4 \cdot 40 + 25 \cdot 4 = 160 + 100 = 260$  kr

Svar:  $E(K) = 45$  och  $V(K) = 260$

ingen  
betydelse

3)