

Stockholms universitet  
Statistiska institutionen

**Skriftlig tentamen** avseende kursen **Introduktion till statistik för statsvetare**

\*\*\*\*\*

Onsdag 27 april 09:00 – 14:00, 2016

Skrivtid: 5 timmar.

Hjälpmedel: Miniräknare, samt vidhäftat formelblad.

Genomgång: 2016-05-16 klockan 15:00 till 16:00 i sal B705.

.....

Tentamen består av fem uppgifter, totalt 50 poäng. För full poäng på en uppgift/deluppgift krävs att tydliga, fullständiga och välmotiverade lösningar samt svar inlämnas.

Lycka till! / Per Marcus

\*\*\*\*\*

1. (10 p.)

På en enhet för psykisk hälsa görs under en månad 30 undersökningar om patienternas intelligens (IQ). Antalet undersökningar per vecka varierar.

- a. Ange vad som här är variabel och vad som är frekvens. För variabeln, ange variabeltyp och datanivå. (2 p.)
- b. När medelvärde och median beräknades för variabeln visade det sig att de erhållna värdena inte var lika. Redogör varför det kan komma sig. (2 p.)
- c. Ange tre olika exempel på spridningsmått, samt diskutera vilket av spridningsmåten som här kan vara att föredra. (3 p.)
- d. Ett 95 % konfidensintervall skapades för intelligensen och intervallet [108;161] erhöles. Redogör för vad detta intervall innebär och vilka slutsatser som kan dras från detta intervall. *Observera att varje observation kan ses som oberoende från de andra.* (3 p.)

2. (10 p.)

En undersökning skall genomföras vid Stockholms Universitets Studentkår för att se hur stort behovet är av parkeringsplatser för studenter vid Stockholms universitet. Du får som uppgift att genomföra denna undersökning.

a. Definiera målpopulation och rampopulation samt redovisa för vad dessa begrepp innebär. (4 p.)

b. Beskriv vad täckningsfel är och hur det påverkar undersökningen, samt vad som skulle kunna vara täckningsfel i den undersökning som Du skall genomföra. (3 p.)

c. En av de frågor som Du ställer till respondenterna är:

"Parkerade du din bil på SU vecka 14?"

Du vet att Kalle (en av respondenterna) har svarat ja på frågan, men att han i själva verket parkerade bilen på SU vecka 13. Han har alltså antingen ljugit eller misstagit sig. Vilken typ av mätfel är detta? Beskriv felet och hur det kan påverka undersökningen. (3 p.)

3. (10 p.)

En urvalsundersökning för att undersöka inställningen hos boende i Bagarmossen till de lekplatser som finns kring centrum där.


a. Redogör för vilka beståndsdelar som totalfelet innehåller. (4 p.)

b. Ge exempel för de systematiska fel som redovisas av Dig i fråga a. *Max ett exempel per systematiskt fel.* (4 p.)

c. En urvalsundersökning kan i vissa fall ge bättre precision än en totalundersökning. Redogör för när en urvalsundersökning är bättre i detta avseende. (2 p.)

4. (10 p.)

Plotten nedan beskriver temperatur utomhus och försäljning av glass. Regressionsmodellen skattades till  $\hat{y} = -29,22 + 7,55x$ .



- a. Vilka av de två variablerna är den beroende och vilken är den oberoende enligt regressionsmodellen ovan? (2 p.)
- b. Redogör för vilken av de skattade värdena som är interceptet samt vilken som beskriver lutningen. Tolka dessa två parameterskattningar. (3 p.)
- c. För den givna modellen är korrelationskoefficienten beräknad till 0,84 och  $R^2$  till 0,70. (5 p.)
  - Tolka korrelationskoefficienten samt redogör för vad den innebär i detta fall.
  - Redogör för vad  $R^2$  betyder samt vad den mäter.

5. (10 p.)

När en urvalsundersökning görs väljs observationer olika beroende på vilken urvalsmetod som väljs.

- a. Redogör kortfattat för nedanstående urvalsmetoder. Redogör även om urvalen är sannolikhetsurval eller inte, samt vad som definierar ett sannolikhetsurval. (8 p.)
  - Obundet Slumpmässigt Urval
  - Stratifierat urval
  - Snöbollsurval
  - Systematiskt urval
- b. Beskriv vad en hjälpvariabel är och hur en sådan kan användas för att få bättre urval. Redogör även vad som händer med sannolikhetsurval om en "dålig" hjälpvariabel används (*det räcker med ett exempel*). (2 p.)

# 1. Beskrivande statistik

## 1.1 Medelvärde, varians, standardavvikelse

Ett statistiskt material består av  $n$  observationer

$$x_1, x_2, \dots, x_n$$

Medelvärdet är

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{\sum x}{n} \quad (1.1.1)$$

Variansen är

$$s^2 = \frac{\sum (x - \bar{x})^2}{n-1} = \frac{\sum x^2 - (\sum x)^2 / n}{n-1} \quad (1.1.2)$$

Standardavvikelsen är

$$s = \sqrt{s^2} \quad (1.1.3)$$

När materialet redovisas i en frekvenstabell, där värdet  $x_i$  förekommer med frekvensen  $f_i$ , är medelvärdet och variansen

$$\bar{x} = \frac{\sum f_i x_i}{n} \quad (1.1.4)$$

$$s^2 = \frac{\sum f_i (x_i - \bar{x})^2}{n-1} = \frac{\sum f_i x_i^2 - (\sum f_i x_i)^2 / n}{n-1} \quad (1.1.5)$$

**Räkneregler**

Om  $y = a + bx$ , där  $a$  och  $b$  är konstanter, är

$$\bar{y} = a + b\bar{x} \quad (1.1.6)$$

$$s_y^2 = b^2 s_x^2 \quad (1.1.7)$$

## 1.2 Regression, korrelation

Regressionslinjen är  $y = a + bx$ .

Regressionskoefficienten är

$$b = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sum (x - \bar{x})^2} = \frac{\sum xy - \sum x \sum y / n}{\sum x^2 - (\sum x)^2 / n} \quad (1.2.1)$$

$$a = \bar{y} - b\bar{x} \quad (1.2.2)$$

Korrelationskoefficienten är

$$r = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}} = \frac{\sum xy - \sum x \sum y / n}{\sqrt{[\sum x^2 - (\sum x)^2 / n][\sum y^2 - (\sum y)^2 / n]}} = b \frac{s_x}{s_y} \quad (1.2.3)$$

Residualvariansen är

$$s_e^2 = \frac{n-1}{n-2} s_y^2 (1-r^2) = \frac{1}{n-2} (\sum y^2 - a \sum y - b \sum xy) \quad (1.2.4)$$

## 1.3 Prisindex

Laspeyres index är

$$\frac{\sum p_t q_0}{\sum p_0 q_0} \cdot 100 \quad (1.3.1)$$

Paasches index är

$$\frac{\sum p_t q_t}{\sum p_0 q_t} \cdot 100 \quad (1.3.2)$$



Stockholms  
universitet

Statistiska institutionen

## Rättningsblad

**Datum:** 27/4-2016

**Sal:** Ugglevikssalen

**Tenta:** Statistik för statsvetare

**Kurs:** Introduktion till statistik för statsvetare

**ANONYMKOD:**

SFS 0003

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					3
Lär.ant. 10	10	10	8	9,5					

EV

POÄNG

47,5 p

BETYG

A

Lärarens sign.

SF5 0003

## 1. Undersökning om patienternas intelligens (IQ)

a) Variabeln är patienternas intelligens (IQ). Denna variabel är kvantitativ, då den antar numeriska värden. Samtidigt är variabeln kontinuerlig, då denna kan anta alla värden inom ett intervall. Datamåttet som föreligger är intervallnivå, då variabeln är numerisk men det finns inte en absolut nollpunkt. Det finns inte en person med  $IQ = 0$ . Vidare går det att använda sig av summa och abstraktion för att göra jämförelser, men det går inte att bilda kvot. Variabeln är kontinuerlig då den kan anta oändligt många värden inom ett intervall.

Frekvensen är antal undersökta patienter. (2 p.)

b) Om erhållna värden av medelvärdet och medianen inte är lika, innebär det att det finns extrema observationer som har påverkat medelvärdet. Om medelvärdet är högre än medianen, finns det en eller fler högstextrema observationer som påverkat medelvärdet. Om medelvärdet är lägre än medianen, finns det en eller fler lägstextrema observationer som påverkat medelvärdet. När det inträffar, betyder det att det finns en sned fördelning, och då kan medelvärdet bli missvisande. I dessa fall är det fördelaktigt att använda sig av medianen, ett lägesmått som visar på det mittreasta värdet efter en rangering, och inte påverkas av extrema observationer. (2 p.)

c) Spridningsmått: Tre exempel på spridningsmått är variationsvidd, kvartilavstånd och standard avvikelsen. Variationsvidden står för skillnaden mellan det största och det minsta värdet. Detta spridningsmått skulle kunna användas i undersökningen för att ta reda på vad skillnaden är mellan den patient som har högst IQ, och den patient som har lägst IQ. Dock får man inte mer information om spridningen än så.

Standard avvikelsen står för hur variationerna i genomsnitt avviker från det aritmetiska medelvärdet. Detta mått brukar vara att föredra, då den bidrar med mer information om spridningen, och kan användas för att analysera den statistiska signifikansen och pröva hypoteser.

Dock anser jag att kvartilavståndet är det mest lämpliga spridningsmålet vid den här undersökningen. Detta därför att det finns en sned fördelning av observationerna och standard avvikelsen, lika så som medelvärdet, kan bli missvisande.

Kvartilavståndet är ett spridningsmått som beskriver inom vilket intervall 50% av de mest centrala observationerna befinner sig i.

(3 p.)

1. d) 95% Konfidenzintervall för intelligensen [108; 161]

Konfidenzintervall är ett specifikt intervall där det sanna värdet av medelvärdet befinner sig i. Det erhållna konfidenzintervallet i undersökningen innebär att det sanna värdet av medelvärdet befinner sig mellan 108 och 161, dvs  $108 \leq \bar{x} \leq 161$ . Dessutom finns 95% säkerhet på att det sanna värdet av medelvärdet befinner sig i just detta intervall.

3 p

10 p

10 p

2. Undersökning för att se hur stort behovet är av parkeringsplatser för studenter vid Stockholms universitet.

a) Målpopulation och Rampopulation.

Målpopulation är de individer/element som man är intresserad av att undersöka. Målpopulationen i Studentkårens undersökning är studenter vid Stockholms universitet som använder sig av parkeringsplatser på universitetet.

Rampopulation är den ram/en/register som man använder sig av för att kunna täcka sin målpopulation. En passande ram för Studentkårens undersökning skulle kunna vara en register av alla studenter som har bil/motorcykel. Alternativt en ram där man kan se vilka studenter som har körkort.

Eftersom det är sannolikt att denna information inte finns, kan man använda sig av register över alla studenter (exempelvis Ladok), välja ut ett urval, och ha med filterfrågor i frågeformuläret när dessa delar ut. På så sätt, kan man identifiera vilka som har bil, vilka som använder sig av parkeringsplatserna och sortera bort eventuell övertäckning.


4 p

b) Täckningsfel är ett systematiskt fel som uppstår när ramen inte överensstämmer med målpopulationen. Det finns två typer av täckningsfel - övertäckning och undertäckning.

Övertäckning skulle kunna uppstå i Studentkårens undersökning om det finns studenter som har bil men inte använder sig av parkeringsplatser på universitetet. Det är alltså de individer som inte är i vår målpopulation men som ändå dyker upp i rampopulationen. Det går att motarbeta detta fel, exempelvis genom att ställa filterfrågor i frågeformuläret och sortera bort övertäckningen.

Undertäckning uppstår när individer i målpopulationen inte täcks av rampopulationen, dvs. de som inte är med i register. Ett exempel skulle kunna vara nya studenter som inte hunnit registrera/suppletas i Ladok, och som har bil och använder sig av parkeringsplatserna. Undertäckningsfel är mer problematiskt då det är information som vi skulle behöva, och inte har. Det blir kostant att täcka undertäckningsfel.

3 p



→ Det kan vara avsiktligt eller  
av misstag.

2 c) Teleskopeffekt: När en respondent placerar en händelse flakigt i tiden, uppstår ett mätfel som kallas för teleskopeffekt. Kalle har anggett i enkäten att han parkerade sin bil på Sv Becken 14, men egentligen var det vecka 13. Kalle har antingen ljugit eller misstagit sig och nu har vi fått ett mätfel i vår undersökning.

Teleskopeffekt kan resultera i en snedvriden bild av verkligheten om den förekommer i flera observationer. För att motarbeta detta kan man replikera frågan flera gånger vid olika tidpunkter för att säkerställa att respondenterna har anggett ett svar som stämmer med verkligheten.

10p 3p

3. Urvalsundersökning för att undersöka inställningen hos boende i Bagarmossen till de lekplatser som finns King Centrum där.

a) Totalfelet

$$MSE = (0) + [Bias(0)]^2$$

↓  
Urvalsfel

↓ Systematiska fel: Mätfel, bortfallsfel, täckningsfel och bearbetningsfel.

Det totala felet är summan av urvalsfel med systematiska fel / Non sampling errors (Mätfel, bortfallsfel, täckningsfel och bearbetningsfel.)

4p.

• Urvalsfel: Avvikelsen mellan det erhållna värdet i det slumpmässiga urvalet och värdet man hade fått i en totalundersökning. Man antar att urvalsfelet i en totalundersökning är lika med noll.

Systematiska fel / Non sampling errors:

- Mätfel: Uppstår när man inte mäter det man vill mäta, alltså fel i mätningen.
- Bortfallsfel: Uppstår när man går miste om information från respondenterna. Detta kan vara objektbortfall, när en respondent inte svarar; eller partiellt bortfall, när en fråga inte besvaras / missuppfattas.
- Täckningsfel: När ramen inte överensstämmer med målpopulationen. Det kan vara under täckningsfel eller övertäckningsfel.
- Bearbetningsfel: När fel uppstår i bearbetningen av materialet. Det kan vara fel i kodningen eller att man slår in flakiga siffror av misstag.

b) Exempel för de systematiska felet i undersökningen i Bagarmossen

• Mätfel: Prestigebias. En av frågorna i enkäten handlade om att ange om man någon gång hade inhandlat parkettika på någon lekplats i Bagarmossen. Andreas valde alternativet "Aldrig" som sitt svar, även om han ett par gånger hade gått till parken för att köpa parkettika. Andreas angav ett svar som han ansåg skulle vara mer "socialt accepterat" men som inte överensstämmer med verkligheten. Det uppstod ett fel i mätningen.

## Fortsättning 3b.

- **Bortfallsfel:** Ett exempel på partiellt bortfall är följande. Peter håller på att svara en enkät om inställningen till lekplatser i Bogarmossen. En av frågorna handlade om hur ofta man besöker lekplatserna i området på en vecka. Peter svarar "10 gånger i veckan" då han måste gå igenom en lekplats varje dag för att ta sig till/han jobbet. Peter ansåg att "gå igenom parken" var svaret på "frekvensen man besöker lekplatsen". De som genomförde undersökningen förväntade sig att respondenterna skulle svara när de besökte parken för nöjes skull. Dock specificeras det ej i frågan och Peter missuppfattar den. **4 p.**

- **Täckningsfel:** Urvalsundersökningen hos boende i Bogarmossen användes folkbokföringen som rampopulation. Dock uppstod det en undertäckning på individer som nyligen hade flyttat in i området och som inte hade hunnit folkbokföras sig. Det visade sig att det var just dessa individer som mest besökte lekplatserna i området.

- **Bearbetningsfel:** Sara och Niklas fick tillbaka en del av enkäterna som de hade skickat ut för att samla in datan om inställningen till lekplatser i Bogarmossen. De skulle sörga registrera allt information i ett datorprogram, som skulle vara till hjälp i bearbetningen av materialet. Dock rådde Sara knäppa in felaktiga siffror på ett par ställen, hon var trött och Niklas var inte uppmärksam nog för att märka detta.

## c) Totalundersökning kontra Urvalsundersökning

En totalundersökning kännetecknas av att inget urvalsfel uppstår. Däremot förekommer systematiska fel som måste bearbetas/skrivas för att minimera felet och garantera hög kvalitet i undersökningen.

En urvalsundersökning kan i vissa fall ge bättre precision än en totalundersökning, då det är mindre data att bearbeta och skattningarna kan bli mer precisa. Dessutom brukar totalundersökningar vara dyra att genomföra. I en urvalsundersökning kan man använda sina ekonomiska resurser på att göra bättre skattningar och minimera felet i större utsträckning. Detta strategi kan vara mer gynnsamt än att investera på databesamlingen och inte ha råd med bra skattningar och mottagande av exempelvis bortfall.

Man bör alltid tänka på vilken typ av undersökning som är att föredra i linje med hur mycket pengar man disponerar för sin undersökning. Med andra ord, ska man ha det minsta felet för minsta antal kronor.

10 p.

## 4. Regressionsmodellen: $y = -29,22 + 7,55x$

a) Enligt regressionsmodellen är den beroende variabeln ( $y$ ) glasförsäljning och den oberoende variabeln ( $x$ ) är temperatur i C. **2 p.**

b) Tolkning av parameter-skattningar i regressionsmodellen:

Interceptet ( $a$ ) är  $-29,22$ . Denna koefficient är startpunkten som utgår från  $y$  axeln i regressionsmodellen. Det innebär att glasförsäljning är  $-29,22$  utan påverkan av temperaturen i C.

Lutningen ( $b$ ) är  $7,55$ , den anger hur regressionslinjen lutar sig i modellen. Det innebär att för varje C grad som temperaturen ökar med, så ökar glasförsäljningen med  $7,55$ . T.ex om det blir  $40$  C så ökar glasförsäljning med  $302$  ( $7,55 \cdot 40$ ) i snitt. **2 p.**

4. c) Korrelationskoefficienten =  $0,84$   
 $R^2 = 0,70$

- Korrelation betyder graden av linjärt samband. Korrelationskoefficient står för hur starkt sambandet mellan variablerna är. Dessutom visar denna koefficient på om korrelationen är positiv eller negativ. Det brukar vara ett värde mellan  $-1$  och  $1$ , dvs.  $-1 \geq r \leq 1$ , där  $r = -1$  tolkas som ett perfekt negativt samband; och  $r = 1$  tolkas som ett perfekt positivt samband.

I vår undersökning, tyder korrelationskoefficienten  $0,84$  på att det finns ett ganska starkt samband mellan glasförsäljning och temperatur i C. Dessutom visar denna korrelationskoefficient på att sambandet är positivt. När temperaturen ökar, så ökar glasförsäljning. Ett samband som även är synligt i Skattningsplotlet.  $E_j$  kausalt.

-  $R^2$  är determinationskoefficient. Denna koefficient mäter i vilken procent variationer i den beroende variabeln (y) förklaras av variationer i den oberoende variabeln (x). Man kan beräkna determinationskoefficienten genom att höja korrelationskoefficienten upp till två.

I det här fallet, visar vår determinationskoefficient  $0,70$  att  $70\%$  av variationerna i glasförsäljning förklaras av variationerna i temperaturen. Denna koefficient tyder på ett starkt samband mellan variablerna.

4p 8p

5. Urvalsundersökningar och urvalsmetoder

a) Definition av sannolikhetsurval: Ett sannolikhetsurval är ett sätt urval där slumpen avgår vilken individer/element som kommer in i urvalet. I ett sannolikhetsurval har alla individer/element en sannolikhet (som är större än noll) att vara med i urvalet. Sannolikhetsurval eller slumpmässiga urval, som det också kallas, kan vara obundet eller riktat.

Urvalsmetoder:

- Obundet slumpmässigt urval: OSU är ett sannolikhetsurval som är obundet eller  $E_j$  riktat. Man låter slumpen avgöra helt vilka individer/element som ska vara med i urvalet. Det är det enklaste sannolikhetsurvalet att genomföra samt det billigaste. Ett problem som kan uppstå är att eftersom slumpen avgör, kan det bli en sned fördelning i urvalet, där det saknas representation av minoriteter, exempelvis. 2p
- Stratifierat urval: Det är ett sannolikhetsurval som går ut på att man delar sin population i olika strata (grupper), där spridningen mellan individerna inom varje stratum ska vara så liten som möjligt. Däremot ska spridningen mellan de olika strata vara så stor som möjligt så att man ska kunna jämföra dem och dra slutsatser.  
 Viktigt att tänka på är att indelningen av populationen ska ske med hjälp av en hjälpvariabel. Denna måste ha ett samband med undersökningsvariabeln. Man genomför ett vanligt OSU i varje stratum efter att indelningen har skett.

## Fortsättning Sa.

- Snöbollsurval: Det är ett icke-sannolikhetsurval där man tar reda på respondenter/ informanter tack vare andra informanter/ respondenter förslag. Det vill säga att de första informanterna/respondenterna leder oss till flera, och de i sin tur föreslår flera, osv.

Denna urvalsmetod används framförallt vid undersökningar som kan uppfattas som känsliga och där en ram med information om individer är svår att hitta. Ett exempel skulle kunna vara en undersökning om kvinnor som har blivit våldtagna som barn.

2p

- Systematiskt urval: Det är ett sannolikhetsurval som går ut på att man rangordnar individer/element i sin ram utifrån en hjälpvariabel. Denna hjälpvariabel ska ha ett samband med undersökningsvariabeln.

Viktigt att tänka på vad det gäller rangordningen är att det ska finnas ekvidistans mellan alla individer/element i raman efter att man rangordnat dem. Därmed väljer man en siffra från 1-0 och systematiskt sitt urval efter detta val. Tex om man slumpmässigt väljer individ/element 7, då får man ta individer/element 7, 17, 27, 37, 47, 57... tills man fyllt sin urvalsfraktion.

1,5 p

b) Hjälpvariabel: En hjälpvariabel är en variabel som används för att dela in eller rangordna individer/element i ett sannolikhetsurval, exempelvis vid stratifierat urval och systematiskt urval.

Hjälpvariabeln som man väljer ska alltid ha ett samband med den variabeln man undersöker, för att kunna säkerställa att man har en passande fördelning i sitt urval. Ett exempel är om man ska undersöka inkomstskillnader i en viss population. Då kan man välja en hjälpvariabel där man indelar/rangordnar sin population från låginkomsttagare till höginkomsttagare.

Om man väljer en "otillig hjälpvariabel", det vill säga en variabel som inte har att göra med undersökningsvariabeln, då blir urvalet ett vanligt OSU, och då har man slöstat tid och resorser i stratifiering/systematisering av sin population, utan framgång.

För att fortsätta med exemplet om inkomstskillnader kan man anta att man väljer "antal hundar" som hjälpvariabel. Eftersom denna hjälpvariabel inte har något samband med undersökningsvariabeln, så blir stratifieringen/systematiseringen misslyckad och urvalet förblir ett vanligt OSU.

2p

9,5



Stockholms  
universitet

Statistiska institutionen

## Rättningsblad

**Datum:** 27/4-2016

**Sal:** Ugglevikssalen

**Tenta:** Statistik för statsvetare

**Kurs:** Introduktion till statistik för statsvetare

**ANONYMKOD:**

SFS-0005

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					7
Lär.ant. 10	8	10	9,5	9					

POÄNG 96,5	BETYG A	Lärarens sign.
---------------	------------	----------------

1) a) Variabeln är patienternas intelligens (IQ), då det är det som vi vill undersöka. Variabeln är kvantitativ då den antar numeriska värden. Vidare ligger den på intervalldata nivå då det går att rangordna & peka ut meningsfulla skillnader mellan variabelvärderna. Den har även en godtycklig nollpunkt då man inte kan ha ett IQ under 0. Den är godtycklig då IQ är ett visst mått på intelligens som vi människors uppfunnit, ungefär som vår tidräkning som också har en godtycklig nollpunkt på år 0. Frekvensen är antalet undersökningar som görs per vecka. (2p)

b) Medelvärdet är det värde man får om man adderar alla variablers värden & dividerar med antalet observationer. Medianen är det mittersta värdet i ett rangordnat material, vilket är medelvärdet är känsligt för extremvärden vilket gör att medelvärdet kan bli något snedviktat om det i detta fall förekommer extremvärden i detta fall. Medianen är

ö andra sidan inte känsligt för extremvärden & påverkas sämre inte av det i lika stor utsträckning som medelvärdet. Att de nämnda värdena, alltså medelvärden & medianen, inte var lika när sättes & göra med det de dels ser till olika aspekter av en fördelning & dels att medelvärdet kan ha påverkas av extremvärden (2p)

c) Variationsvidd = Skillnaden mellan det största & minsta värdet

Standardavvikelse = Hur värdena i fördelningen avviker från medelvärdet

Kvantilavstånd = Skillnaden / avståndet mellan den första & tredje kvantilen;  $Q_1 - Q_3$

Variationsvidden säger endast något om det största & minsta värdet vilket blir något intetsägande i detta fall då det utelämnar resterande värden som också är av intresse. Därav utelämnas variationsvidden.

I & med det som jag diskuterade i föregående fråga (om hur medelvärden är känsligt för extremvärden) så kan standardavvikelsen i detta fall ge en något missvisande bild av spridningen eftersom den hänger i hop med medelvärden. Kvantilavståndet är att föredra i detta fall då det mäter hängslet i hop med medianen (som ej är känsligt för extremvärden) & kan säkres ge en bra bild av spridningen av de mittersta observationerna. (3p)

d) Ett konfidensintervall är en skattning av osäkerheten kring de skattade parametervärdena som tagits fram genom ett stickprov. Det visar också med hur stor sannolikhet det samma värdet återfinns inom intervallet. Ett 95% konfidensintervall innebär att vi med 95% sannolikhet kan säga att det samma parametervärdet återfinns inom intervallet. I detta intervall  $[108; 161]$  så kan vi med 95% säkerhet anta, att det i 95% av alla stickprov, så kommer det samma parametervärdet ligga mellan 108 & 161.

I detta fall kan man också säga att ex. det samma populationsmedelvärdet för intelligens hos patienterna & det skattade populationsmedelvärdet för intelligens kommer inom intervallet  $[108; 161]$  med 95% säkerhet att överensstämmer med varandra.

10p

② a) Målpopulation: de vi ideellt vill undersöka.  
I detta fall kan målpopulationen utgöras av  
samtliga studenter som studerar vid Stockholms  
Universitet. Råmpopulation är de vi kan  
undersöka, detta är de vi kan nå genom något  
slags register eller förteckning. Råmaterialet  
skulle i detta fall kunna vara registrerade  
studenter vid Stockholms Universitet. 3p

b) Täckningsfel uppstår när målpopulationen &  
ramen inte överensstämmer med varandra.  
Exempel är underförteckning som innebär att  
individer som tillhör målpopulationen inte  
finns med i registret & således har  
0 inkluderings sannolikhet att komma med i  
urvalet. Överförteckning är även det ett täcknings-  
fel, och uppstår när individer finns med i  
ramen men inte i målpopulationen  
vilket gör att man får med folk i sin  
undersökning som egentligen inte  
är av intresse. Täckningsfel som kan  
uppstå i den tänkta undersökningen är  
studenter vid Stockholms Universitet &  
bilskolan av parkeringsplatser är av  
både underförteckning & överförteckning.



Undertäckning kan uppstå om ex. Studenter som studerat vid SU gjort att registrera sig på kursen, eller om det är något tekniskt fel blivit fel i registerningen så att man inte vet vilka dessa är & säkerhets inte kommer med i urvalet. Även undertäckning kan uppstå om det även har kanske blivit något fel i registerningen där ex. vissa personer har registrerat sig på en kurs som studenter fastän de sedan hoppat av & inte studerar längre & att registerningen inte blivit uppdateras. Detta skulle också innebära undertäckning då de kommer med i urvalet men inte tillhör målpopulationen då de inte studerar på Stockholms Universitet.

För att sammanfatta frågan så blir frågan felut med unders & undertäckning att undersökningen blir något missivande då den inte helt & hållet speglar den verkliga populationen, målpopulationen som vi vill undersöka.

○ Måttet har i göra med såväl mätinstrument, respondent, intervjuare & mätmetod, i detta fall kan kallas felaktiga svar bero på att man vill komma med i undersökningen då man tycker att det är "intressant" att hans svar kommer med i undersökningen, detta kan då ha och göra med respondenten i fråga. Att respondenten vill komma med i undersökningen då denne ansvar sin åsikt svar som mätare

FDAS, Fråga 2.

Väsentligt för undersökningsresultatet. Det kan även ha & göra med mätinstrumentet & mätmetoden. Om jag ex. varit otydlig i ett eventuellt frågeformulär så kanske det har & göra med med det. Eller om det är en intervju så kanske jag omedvetet påverkar källa att svara ett visst svar vilket kallas intervjuarefekten. Mätfelet påverkar givetvis mätvärden till det samma då svaret inte är sanningsenligt vilket bidrar till snedvridna resultat i mätvärdena. (8p)

⑤ a) Totalfelet = Urvalsfel + täckningsfel + bearbetningsfel + bortfallsfel + mätfel.

(Urvalsfel = de fel som uppstår i & med det vi enkelt dragit ett stickprov från populationen & ändå vill dra slutsatser om det. (4p))

b) Bortfallsfel → Det fel som uppstår i min undersökning om vissa svar / individer uteblir. Partikulärt bortfall är när en viss variabel utelämnas, dvs att det ex. kan bero på att en respondent inte besvarat en viss fråga. Individbortfall uppstår ex. om jag skickar ut postenkäter och vissa individer inte svarar på enkäten.



Fäckningsfel uppstår då målpopulationen & rampopulationen inte överensstämmer med varandra. Kan ex. ske om jag ska undersöka 16-24 åringar i en viss kommun & ska utgå från förebortningsregistret som ram, & så kanske vissa har skyddad i domstol & inte finns med i registret. Detta leder till ett utvärteringsfel.

Beaktningsfel → uppstår vid ex. registreringer om datorn eller kodningen av svar osv. Det kan ex. hända att jag som människa ska sköta & fira registreringer av svaren till en dator, så finns det stor sannolikhet att något svar kommer registreras felaktigt, detta blir ett beaktningsfel pga. av den utsläppta faktorn (man är ingen dator).

Mätfel → Har & göra med såväl respondenter, intervjuaren, mätinstrument & mätmetod. Är dessa stillade mellan samt & emellan värde. Mätfel kan ex. uppstå om respondenter inte framstår i god dager & inte besvarar ett ex. frågeformulär samtyckligt. Säg att det handlar om alkoholkonsumtion & respondenter kryssar i att den konsumerar mindre alkohol än vad denne faktiskt egentligen gör. Detta leder då till ett mätfel som kallas prestige-bias.

7p

FOAS-Fråga 3

3) c) Det är bättre att genomföra en kvantitativ undersökning om målpopulationen är extremt stor. Detta då det exempelvis skulle vara väldigt svårt att undersöka ex. alla i hela Sverige. En totalundersökning för alla i hela Sverige skulle dock innebära extrema kostnader, extremt mycket tid, det skulle även med stor sannolikhet uppstå stora bortfallsfel då det rent ut sagt skulle vara nästan omöjligt att få tag i alla plus att många inte ens skulle svara frivilligt. Många systematiska fel skulle också uppstå. Det kan dock vara bättre med en kvantitativ undersökning då man kan, när man undersöker färre personer, lägga mer tid & pengar på att få svar från dessa samt att bortfallet då kan minska då man eventuellt skulle kunna ha råd att erbjuda de som svarar en gåva eller liknande. Det detta talar för att en kvantitativ undersökning är att föredra i detta fall då det ger mer precision. (2p) (10p)

4) a) beroende variabeln = glassförsäljning  
oberoende variabeln = temperatur i C utomhus.

(2p)

b)  $\hat{y}_1 = -29,22 + 7,55x$ . Interceptet är  $-29,22$  som står för  $a$ . Detta är var regressionslinjen skär y-axeln & är även det värde som  $y$  i genomsnitt antar när  $x = 0$ . Det går alltså att säga att det är linjens startpunkt. Lutningen är  $7,55$  & står för  $b$ , detta är även kallat riktningskoefficienten / regressionskoefficienten. Denna parameterstyrning visar hur mycket  $y$  ändras när  $x$  ökar med en enhet. I detta fall har vi en positiv lutning ( $7,55$ ) som innebär att när  $x$  ökar med en <sup>förändring i</sup> ~~enhet~~ <sup>smitt.</sup> så ökar även  $y$ . I detta fall (2,5 p) så kan man se att när temperaturen ökar ( $x$ ) så ökar även glassförsäljningen ( $y$ ).

c) Korrelationskoefficienten anger graden av linjärt samband, alltså huruvida två variabler samvarierar eller inte. Perfekt positivt samband är  $+1$  & perfekt negativt samband är  $-1$ . I detta fall är korrelationskoefficienten  $0,84$  vilket tyder på en väldigt stark korrelation mellan glassförsäljning & temperatur i  $^{\circ}\text{C}$  utomhus. I & med det det är en positiv korrelation så innebär det att en ökning på  $x$ -axeln motsvaras av en ökning på  $y$ -axeln när temperaturen stiger så ökar även glassförsäljningen. Nämnvärt är dock att detta inte säger något om orsak & verkan utan endast om korrelation.

Fråga 4 forts. c)

c)  $R^2$  står för determinationskoefficienten. Den anger hur stor del av variationerna i  $y$  som kan förklaras av variationerna i  $x$ . I detta fall uppgick  $R^2$  till 0,70 vilket innebär att 70 procent av variationerna i glasförsäkring ( $y$ ) kan förklaras av variationerna i temperatur i Celsius ( $x$ ).

(5 p.)

(9,5 p)

(5)

a) Obundet slumpmässigt urval är ett sannolikhetsurval då alla individer i populationen har en inklusions-sannolikhets som är lika stor. Obundet slumpmässigt urval innebär att alla individer i populationen har samma inklusions-sannolikhets att komma med i urvalet. Detta går att göra vid två olika tillfällen: 1) Lotten går till. Detta urval är helt obundet & oriktat & blir således i många fall som en miniatur av populationen.

(2 p.)

Stratifierat urval är även det ett sannolikhetsurval då alla individer i populationen har en inklusions-sannolikhets som är lika stor i urvalet. I detta urval så delar man in sin population i subpopulationer, s.k. strata, där varje strata representerar en del av populationen. Man stratifierar alltså

Populationen efter någon lämplig stratifieringsvariabel. Sedan drar man ett OSU eller ev. ett proportionerligt urval från varje strata. (I ett stratifierat urval så eftersträvar man så liten spridning som möjligt inom stratumet men stor spridning mellan respektive stratum.) När man sedan dragit ex. ett OSU från varje stratum så får varje strata sin egna spridning. (2 p)

Snöbollsurval är inte ett sannolikhetsurval då alla individer inte har en interventionschans att bli utvalda med i urvalet. Ett Snöbollsurval går till på så sätt att man först kontaktar en person som anses vara relevant för urvalet & sedan låter denna person föra en till nästa person osv, osv. Detta urval är alltså således ganska riktat. (2 p)

Systematiskt urval är ett sannolikhetsurval. Detta urval går till så att man först bestämmer sig för hur stor andel av populationen man vill undersöka. Säg 10%. Då väljer man slumpmässigt ut en siffra mellan 1-10. Säg att det blir 4. Då låter vi individer med nummer 14, 24, 34 osv automatiskt ingå i urvalet. Här måste dock individerna vara nummerade i någon föredning / register för att det ska vara möjligt att genomföra denna typ av urval. (2 p)

FDAs. träna 5

5 b) En hjälpvariabel är en variabel som hjälper mig att sortera mina observationer. Om jag ex. genomför ett stratifierat urval (summonterat urval) så är det av stor vikt att ha en bra hjälpvariabel. Säg att jag ska göra ett urval av olika företag, då kan det vara relevant att stratifiera utifrån storleken på dessa företag. Därför vill jag min hjälpvariabel vara storlek: ex små företag, medelstora & stora företag. Hjälpvariabeln hjälper mig säkerställa att sortera för att få mer precision i mina skattningar. Om jag, i detta fall inte sorterat mina företag utifrån hjälpvariabeln "storlek" så hade det kunnat bli ett missivande resultat då slumpen skulle kunna orsaka så att ex. jättemånga stora företag & jättefå små företag kommer med i undersökningen. Detta skulle leda till ett icke representativt resultat. Har man en dålig hjälpvariabel att sortera efter så kommer urvalet bli icke representativt & snedvridet.

(E) 7p