

13/1  
2021  
sid 1

# Undersökningsmetodik

Anonymkod:

0009-EFL

## Uppg ①

Andelen positiva

$$\frac{\alpha}{2} = 0,025$$

$\rightarrow z = 1,96$  : Tabell 2

a)  $N = 300$       95% KI  
Felmarginal = 0,05      } Given info

$$zD = 0,05 \quad D = \frac{0,05}{1,96}$$

$\sigma^2$  okänt  $\rightarrow$  Antar därmed största möjliga.  $p = 0,5 \rightarrow p(1-p) = \sigma^2$

$$\sigma^2 = 0,5(1-0,5) = 0,25$$

$$n \geq \frac{N\sigma^2}{D^2(N-1) + \sigma^2} \rightarrow \frac{300 \cdot 0,25}{\left(\frac{0,05}{1,96}\right)^2 (300-1) + 0,25}$$

$$n = \frac{75}{0,44458} = 168,698 \approx 169 \text{ st i urvalet}$$

b)  $n = 80$  } Givet.  
64 st positiva

90% KI Andelen

$\alpha/2 = 0,05 \rightarrow z = 1,6449$

Tabell 2:

$$\hat{p} = \frac{\sum y_k}{n} = \frac{64}{80} = 0,80$$

$$\frac{80}{300} = 0,267 > 0,1$$

Anv. Ändlighetskorrektur

$$\hat{V}(\hat{p}) = \left(1 - \frac{n}{N}\right) \frac{\hat{p}(1-\hat{p})}{n-1}$$

$$= \left(1 - \frac{80}{300}\right) \cdot \frac{0,8 \cdot (1-0,8)}{80-1}$$

$$= 0,001485232$$

$$KI: \hat{p} \pm z_{\alpha/2} \sqrt{\hat{V}(\hat{p})}$$

$$0,80 \pm 1,6449 \cdot \sqrt{0,001485}$$
$$0,80 \pm 0,06339$$

$$(0,73661, 0,86339)$$

- c) Det kan anses rimligt att tro att fler än 70% är positiva då KI antyder att i 90 fall av 100 ligger det sanna värdet inom  $\approx 73,6\%$  till  $86,3\%$ .

Det är även ett "ok" urvalstorlek inte det kanske bäst lämpade men eftersom att

$n > 30$  "duger" det för att göra generaliseringar utifrån antagandet CGS (centrala gränsvärdesatsen) dvs. troligen normalfördelat urval.

sid. 3

Uppl. 2

Givet:

- \* Stratifierat urval
- \* Ändlighets korrektion.

By	$N_k$	$n_k$	$\bar{y}_k$	$s_k$	$W_k$
N	890	50	95000	40000	0,20892
C	2200	150	65000	30000	0,51643
S	1170	100	50000	20000	0,27465
$\Sigma$	4260	300			1,00

a) uppskatta hushållens medelinkomst i kommunen

$$95\% \text{ KI} \quad \alpha/2 = 0,025 \rightarrow Z = 1,96$$

$$\bar{y}_{STR} = \sum_{k=1}^L W_k \bar{y}_k$$

$$W_k = \frac{N_k}{N}$$

$$95000 \cdot 0,20892 + 65000 \cdot 0,51643 + 50000 \cdot 0,27465$$

$$= 67147,85$$

$$\hat{V}(\bar{y}_{STR}) = \sum_{k=1}^L W_k^2 \left(1 - \frac{n_k}{N_k}\right) \frac{s_k^2}{n_k} =$$

$$0,20892^2 \cdot \left(1 - \frac{50}{890}\right) \cdot \frac{40000^2}{50}$$

$$+ 0,51643^2 \cdot \left(1 - \frac{150}{2200}\right) \cdot \frac{30000^2}{150}$$

$$+ 0,27465^2 \cdot \left(1 - \frac{100}{1170}\right) \cdot \frac{20000^2}{100} =$$

$$1318254,59 + 1491095,146 + 275941,5592$$

$$= 3085291,295$$

$$\bar{y}_{STR} \pm Z_{\frac{\alpha}{2}} \cdot \sqrt{\hat{V}(\bar{y}_{STR})} \rightarrow 67147,85 \pm 1,96 \cdot \sqrt{3085291,295}$$

$$= 67147,85 \pm 3442,7395$$

$$\text{KI: } (63705,1105 ; 70590,5895)$$

13/1  
2021

Anonymkod

0009 - EFL

sid. 4 Upg 2. Fort.

b) Ny undersökning. Utgå från  
given data.

Urvalsallokering som kan minimera  
felmarginalen.

$$n = 300.$$

→ Neyman allokering / optimal allokering  
är lämpligast för att minimera  
felmarginalen.

$$n_k = n \cdot \frac{N_k \sigma_k}{\sum_{j=1}^L N_j \sigma_j} \quad \sigma_k = s_k$$

$$\sum N_j \sigma_j = 890 \cdot 40000 + 2200 \cdot 30000 + 1170 \cdot 20000 = 125000000$$

$$n_n = \frac{890 \cdot 40000}{125000000} \cdot 300 = 85,44 \approx 86$$

$$n_c = \frac{2200 \cdot 30000}{125000000} \cdot 300 = 158,40 \approx 158$$

$$n_s = \frac{1170 \cdot 20000}{125000000} \cdot 300 = 56,16 \approx 56$$

300

Norrbyn  $n = 86$

Centrum  $n = 158$

Södbyn  $n = 56$

← Rimligt att Norrbyn  
har högre  $n$  än  
Södbyn då dess  
standardavvikelse  
är dubbelt så stor.

13/1  
2021

Anonymkod

0009-EFL

sid. 5

Upg ③

a) Kvalitetskriterier

2st: samt möjlig  
måtkonflikt

1. Punktlighet

2. Noggrannhet.

1. Framställningstid;  
tillgänglig vid  
angivet datum.

Måtkonflikt: om man ska  
hålla sig inom given tidsram  
är det inte säkert att man  
kan göra allt så noggrant  
som man skulle behöva.  
För att säkerställa kvaliteten.

2. Hur väl överstämmer  
skattningarna med det (okända) sanna värdet?

b) Systematiskt urval: Används om man ex har  
en sorterad ram. Ex personers namn

i kursen statistik 1 sorterat i bokstavsordning.  
För att dra ett slumpmässigt urval väljs först  
vilka som ska väljas via  $\frac{N}{n} = r$ , och  
därefter väljs en  
startpunkt ( $t$ )  $t: 1 \leq t \leq r$ . Och sedan väljs  
var  $r$ :te person.

Då  $t$  väljs slumpmässigt har alla element möjlighet  
att bli dragna. Fördelar: enkelt att genomföra,  
Om ramen är lämpligt sorterad. Fås hög precision.

Nackdel: Risk för periodicitet!

Urval

$i=1,2,\dots,20$   
c) Bortfall effekt: Urvalet kan bli snedvridet om  
ex alla som svarar är "stugsittare" dvs  
ej representativa för urvalet.

1, 5, 9  
12, 16  
= urvalet  
ex om man undersöker andelen positiva till "A"  
så finns en risk att bortfallet består av  
en större majoritet "negativa".

Det leder till en större osäkerhet i skattningarna  
vilket kan påverka trovärdigheten och kvaliteten  
på undersökningen

d) Sannolikhetsurval: Definition "varje element i  
populationen har en känd inklusionssannolikhet,  
och denna är större än 0" (Behöver dock ej vara  
lika stora)

Fördelar jämfört med icke-sannolikhetsurval:

\* Går att beräkna vvr skattningar såsom medelvärde  
och totalvärde av de okända populations  
parametrarna.


\* Vi kan dra slutsatser om populationen utifrån  
urvalet

\* Vi kan beräkna osäkerheten i skattningarna

Ex på sannolikhetsurval är OSU, stratifierat  
urval &  
systematiskt urval.

Äpplen  $x_i = \text{vikt}$

$y_i = \text{juicemängd}$



Om man placerar givna värden i en graf kan man utläsa ett positivt samband.

När  $x$  ökar, ökar  $y$ .

Vi kan även ana att om vi ritar en linjär linje är det möjligt att den går igenom origo. (se linje i grafen)

Det ser även ut att vara ett linjärt samband.

Därför anser jag att kvotestimator är lämplig att använda för att uppskatta mängden juice.

Vi har även informationen  $x_x =$  totala vikten av partiet och då kan vi använda  $x$  som en hjälp-information för att skatta  $y$ .

13/1-2021

Anonymkod

0009-EFL

sid 7

Uppg (4) Fort.

b) uppskatta tot. mängden juice.

$$\begin{aligned} n &= 15 & \sum x_i &= 195,4 = 10 + 11,8 + \dots + 7,3 + 15,9 \\ & & \sum x_i^2 &= 2694,32 = 10^2 + 11,8^2 + \dots + 7,3^2 + 15,9^2 \end{aligned}$$

$$\tau_x = 40000 \text{ g} \quad \bar{x} = \frac{195,4}{15} = 13,02667 = \frac{\sum x_i}{n}$$

$$\begin{aligned} = 40 \text{ kg} & & \sum y_i &= 129,4 = 7,3 + 6,8 + \dots + 5 + 10 \\ & & \sum y_i^2 &= 1198,38 = 7,3^2 + 6,8^2 + \dots + 5^2 + 10^2 \end{aligned}$$

$$\bar{y} = \frac{129,4}{15} = 8,62667 = \frac{\sum y_i}{n}$$

$$\hat{\tau}_{kvot} = \hat{R} \cdot \tau_x = \frac{\sum y_k}{\sum x_k} \cdot \tau_x$$

$$= \frac{129,4}{195,4} \cdot 40000 = 26489,25281$$

$$\approx 26489,25 \text{ g}$$

$$= 0,66223132$$

$$\approx 26 \text{ kg och } 489,25 \text{ g}$$

c)  $\hat{V}(\hat{\tau}_{kvot})$  utan Ändlighetskorr.  $(1 - \frac{n}{N})$ 

$$= N^2 \cdot \frac{1}{n} \cdot \left( \frac{\sum (y_k - \hat{R}x_k)^2}{n-1} \right)$$

$$\sum (y_k - \hat{R}x_k)^2 = \sum y_k^2 - 2\hat{R} \sum x_k y_k + \hat{R}^2 \sum x_k^2$$

$$\sum x_k y_k = (10 \cdot 7,3) + (11,8 \cdot 6,8) + \dots + (7,3 \cdot 5) + (15,9 \cdot 10) = 1789,62$$

$$\begin{aligned} \rightarrow 1198,38 - (2 \cdot 0,66223132 \cdot 1789,62) + (0,66223132^2 \cdot 2694,32) \\ = 9,822517853 \end{aligned}$$

$\rightarrow$  Vi vet inte  $N \rightarrow$  skattar via att ta totala vikten delat på medel och får då en möjlig skattning av antalet.

$$\frac{\tau_x}{\bar{x}} = \frac{40000}{13,02667}$$

$$= 3070,62436 \approx 3071 = N$$



13/1-2021

$$3071^2 \cdot \frac{1}{15} \cdot \left( \frac{9,822517853}{15-1} \right) \\ = 441126,5171 = \hat{V}(\hat{\tau}_{kvot})$$

vi kan däremot skatta  $\hat{V}(\hat{\mu}_{kvot})$  då det inte krävs att vi vet  $N$ .

$$\rightarrow \frac{1}{n} \cdot \left( \frac{\sum (y_k - \hat{R}x_k)^2}{n-1} \right)$$

vilket är "samma" formel som för  $\tau_{kvot}$  men utan  $N^2$

$$\rightarrow \frac{1}{15} \cdot \left( \frac{9,822517853}{15-1} \right) = \\ 0,046773894$$

och då vet vi att  $\hat{V}(\hat{\tau}_{kvot})$  är  $N^2 \cdot 0,046773894$  för det sanna värdet på  $N$



13/1  
2021

Anonymkod

0009 - EFL

sid 9

Upg 5.

$$N = 5 \quad U = \{1, 4, 5, 6, 9\}$$

$$a) \quad \bar{y} = \frac{1}{N} \cdot \sum y_k = \frac{1+4+5+6+9}{5} = 5$$

$$\sigma_y^2 = \frac{\sum y_k^2 - N \bar{y}^2}{N} = \frac{159 - 5 \cdot 5^2}{5}$$

$$\sum y_k^2 = 1^2 + 4^2 + 5^2 + 6^2 + 9^2 = 159 = 6,8$$

b) Möjliga urval  $n=2$  OSU med återläggning

Möjliga urval  $\bar{y}$

1, 1	1
1, 4	2,5
1, 5	3
1, 6	3,5
1, 9	5
4, 1	2,5
4, 4	4
4, 5	4,5
4, 6	5
4, 9	6,5
5, 1	3
5, 4	4,5
5, 5	5
5, 6	5,5
5, 9	7
6, 1	3,5
6, 4	5
6, 5	5,5
6, 6	6
6, 9	7,5
9, 1	5
9, 4	6,5
9, 5	7
9, 6	7,5
9, 9	9

Med hänsyn till ordning: = 25

utan hänsyn till ordning:

$$C_n^{N+n-1} = C_2^{5+2-1} = 15$$

Möjliga urval

		$\bar{y}$	$s_y^2$
1	1, 1	1	0
2	1, 4	2,5	4,5
3	1, 5	3	8
4	1, 6	3,5	12,5
5	1, 9	5	32
6	4, 4	4	0
7	4, 5	4,5	0,5
8	4, 6	5	2
9	4, 9	6,5	12,5
10	5, 5	5	0
11	5, 6	5,5	0,5
12	5, 9	7	8
13	6, 6	6	0
14	6, 9	7,5	4,5
15	9, 9	9	0

dä  $n=2 \Rightarrow$   
 $s^2 = \frac{(y_i - y_j)^2}{2}$

$\leftarrow \frac{(4-5)^2}{2}$

$\leftarrow \frac{(5-9)^2}{2}$

$\leftarrow \frac{(9-9)^2}{2}$

$$\sum 75 \quad 85$$

$$\bar{y} = \frac{75}{15} = 5 = \frac{\sum y_i}{n} \quad n=15$$



Uppg 5. Fort.

$$b) \sigma_{\bar{y}}^2 = \frac{\sum (\bar{y}_i - \bar{\bar{y}})^2}{N} = \frac{59,5}{15}$$

	$\bar{y}_i - \bar{\bar{y}}$	$\bar{y}_i - \bar{\bar{y}}$	$(\bar{y}_i - \bar{\bar{y}})^2$
1	1 - 5 = -4		16
2	2,5 - 5 = -2,5		6,25
3	3 - 5 = -2		4
4	3,5 - 5 = -1,5		2,25
5	5 - 5 = 0		0
6	4 - 5 = -1		1
7	4,5 - 5 = -0,5		0,25
8	5 - 5 = 0		0
9	6,5 - 5 = 1,5		2,25
10	5 - 5 = 0		0
11	5,5 - 5 = 0,5		0,25
12	7 - 5 = 2		4
13	6 - 5 = 1		1
14	7,5 - 5 = 2,5		6,25
15	9 - 5 = 4		16
		$\Sigma$	59,5

N=15

= Antal

olika

stickprov

här.

$$\frac{59,5}{15} = 3,96667 = \sigma_{\bar{y}}^2$$

c) Nej enbart  $\bar{\bar{y}}$  är vvr  
(medelvärde av medelvärden)

Men  $\sigma_{\bar{y}}^2$  är inte vvr då

$$\sigma_{\bar{y}}^2 \neq \sigma^2 \quad 3,96667 \neq 6,8$$

Detta beror nog på att  $y_i$  har dragit ett urval med återläggning och det bidrar till att "samma" kan komma med i urvalet och då blir variansen för det urvalet 0.

Men i verkligheten finns det en skillnad mellan alla element då och därmed

$$1 \neq 4 \neq 5 \neq 6 \neq 9$$

bör det ilte uppkomma 0 i varians i ett representativt urval!

d) Upp 5 Forts.

$$\hat{v}(\bar{y}) = \left(1 - \frac{n}{N}\right) \frac{s^2}{n} \quad \rightarrow \quad \left(1 - \frac{2}{5}\right) \frac{s^2}{2}$$

	$s^2$	$\hat{v}(\bar{y})$	
1	0	0	$\frac{25,5}{15} = 1,7 = \frac{\sum \hat{v}(\bar{y}_i)}{n}$ $n = 15$
2	4,5	1,35	
3	8	2,4	
4	12,5	3,75	
5	32	4,6	
6	0	0	
7	0,5	0,15	
8	2	0,6	
9	12,5	3,75	
10	0	0	
11	0,5	0,15	
12	8	2,4	
13	0	0	
14	4,5	1,35	
15	0	0	
		<hr/> 25,5	

$$v(\bar{y}) = \left(\frac{N-n}{N-1}\right) \frac{\sigma^2}{n} = \left(\frac{5-2}{5-1}\right) \frac{6,8}{2} = 2,55$$

Inte heller här blir

$$v(\bar{y}) = \hat{v}(\bar{y}) \quad \text{då}$$

$$2,65 \neq 1,7.$$

Hade vi tagit bort alla "lika" och då alla med variansen 0 att ta hänsyn till i n hade vi haft  $n=10$  och då hade

$$v(\bar{y}) = \hat{v}(\bar{y}) \quad \text{stämt eftersom}$$

$$\frac{25,5}{10} = 2,55 \quad \checkmark$$

Så för att få vår skattning krävs det ett urval UTAN återläggning.