

FØRRELFSNING 12

Eivind Eriksen MAR 06 2012

MET 3431

STATISTIKK

PLAN:

- ① Normal fordeling : fordelinger til en observator (6.4-6.5)
- ② Kap. 7

Fordelingen til en observator

Observatorfordeling (eng: sampling distribution)

I seksjon 6-4 handler det om å forstå at en observator er en tilfeldig variabel. Den har derfor en sannsynlighetsfordeling. Denne kalles observatorfordelingen .

Estimator

Ofte er en observator ment å skulle estimere en populasjonsparameter. Da kalles observatoren for en estimator.

Example

Tenk deg at du tar mange stikkprøver, hver på størrelse n .

- \bar{X} er en estimator for μ
- Denne estimatoren variererer fra stikkprøve til stikkprøve (eng: sampling variability)

Forventningsrette estimatorer

Table 6-7 Sampling Distributions of Statistics (for Samples of Size 2 Drawn with Replacement from the Population 1, 2, 5)

Sample	Mean \bar{x}	Median	Range	Variance s^2	Standard Deviation s	Proportion of Odd Numbers	Probability
1, 1	1.0	1.0	0	0.0	0.000	1	1/9
1, 2	1.5	1.5	1	0.5	0.707	0.5	1/9
1, 5	3.0	3.0	4	8.0	2.828	1	1/9
2, 1	1.5	1.5	1	0.5	0.707	0.5	1/9
2, 2	2.0	2.0	0	0.0	0.000	0	1/9
2, 5	3.5	3.5	3	4.5	2.121	0.5	1/9
5, 1	3.0	3.0	4	8.0	2.828	1	1/9
5, 2	3.5	3.5	3	4.5	2.121	0.5	1/9
5, 5	5.0	5.0	0	0.0	0.000	1	1/9
Mean of Statistic Values	$8/3$	$8/3$	$16/9$	$26/9$	1.3	$2/3$	
Population Parameter	$8/3$	2	4	$26/9$	1.7	$2/3$	

Alle stikkprøver av
størrelse $n = 2$

Noen estimatorer er
forventningsrette

• \hat{X}
• \hat{s}^2

• \hat{p}

Noen er ikke:

• Median

• Variasjonsbredde

• s

- Does the sample statistic target the population parameter?
- Yes
 - No
 - No
 - Yes
 - No
 - Yes

Seksjon 6-5

Prosedyrene i denne seksjone er grunnlaget for å estimere populasjonsparameter og for hypotesetesting.

Notasjon

- $\mu_{\bar{x}}$ er gjennomsnittet til \bar{x}
- $\sigma_{\bar{x}}$ er standardavviket til \bar{x}

Sentralgrenseteoremet

- Anta at vi har en stor stikkprøve av x -er fra en populasjon med gjennomsnitt μ og standardavvik σ
- Da vil gjennomsnittet \bar{x} være normalfordelt med

$$\mu_{\bar{x}} = \mu, \quad \sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$$

Sentralgrenseteoremet

Vi antar at:

- ① Den tilfeldige variabelen x har gjennomsnitt μ og standardavvik σ .
- ② Man tar mange tilfeldige utvalg av størrelse n fra populasjonen

Da følger det at:

Sentralgrenseteoremet

- ① Fordelingen til \bar{x} blir mer og mer lik en normalfordeling når n er vokser
- ② Gjennomsnittet til \bar{x} er μ
- ③ Standardavviket til \bar{x} er σ/\sqrt{n}

Sentralgrenseteorem demo i JMP

JMP Demo

- ① Åpne fila *C:\Program Files\SAS\JMP\8\Support Files English\Sample Data*
- ② Velg *Rows>Add rows* og legg til 200 rader

Variabelen $N = 50$ inneholder en formel for gjennomsnittet av $n = 50$ tilfeldige variable. Når vi adderer 200 rader, så simulerer vi 200 stikkprøver på størrelse $n = 50$.

Praktiske regler + Notasjon

Når kan vi stole på sentralgrenseteoremet?

- ① Når stikkprøven er større enn $n = 30$
- ② Hvis x' ene selv er normalfordelte, så gjelder sentralgrenseteoremet for alle stikkprøvestørrelser.

Vekt igjen

Example

Anta at vekten på menn er normalfordelt


- Gjennomsnitt $\mu = 172$ pounds
- Standardavvik på $\sigma = 29$ pounds.

Finn:

- ➊ Sannsynligheten for at tilfeldig mann veier mer enn 175 pounds?
- ➋ 20 menn er tilfeldig utvalgt. Hva er sannsynligheten for at deres gjennomsnittsvekt er mer enn 175 pounds?

Vekt igjen, spørsmål 1

$$Z = \frac{175 - 172}{29} = 0.10$$



Figur: Sannsynligheten er 0.4602 for at en mann veier mer enn 175

Vekt igjen, spørsmål 2

$$\bar{X} = \frac{x_1 + x_2 + \dots + x_{20}}{2}$$

Normalfordelt:

$$\begin{aligned}\mu_{\bar{X}} &= \mu = 172 \\ \sigma_{\bar{X}} &= \frac{\sigma}{\sqrt{20}} \approx 6.48\end{aligned}$$


$$Z = \frac{175 - 172}{\frac{29}{\sqrt{20}}} = 0.46$$

$$\frac{3}{6.48}$$

0.6772

0.3228

$\neq 1 - 0.6772$




$$\mu_{\bar{X}} = 172$$

$$(\sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}} = \frac{29}{\sqrt{20}} = 6.4845971)$$

Figur: Sannsynligheten er 0.3228 for at 20 mann veier mer enn 175 i snitt

Vekt igjen, Oppsummering

- Sannsynligheten for at 1 mann veier mer enn 175 er
$$P(x > 175) = 0.4602$$
- Sannsynligheten for at 20 mann i snitt veier mer enn 175 er
$$P(\bar{x} > 175) = 0.3228$$
- Det er lettare for en enkelt mann å veie mer enn 175 enn det er for 20 menn å veier mer enn 175 i snitt!




Kritiske verdier
til 2.5%


95% ↔ 1.96

To viktige kritiske verdier


$95\% \leftrightarrow 1.96$



$90\% \leftrightarrow 1.645$



Oversikt Kapittel 6



Høyden til kvinnene i en populasjon er normalfordelt med gjennomsnitt 170cm og standardavvik 4cm. Hva er sannsynligheten for at en tilfeldig kvinne er over 178cm?

a) 0.02


b) 0.05

c) 0.08

d) 0.10

e) Vetkje

$$\text{z-verdi: } \frac{178 - 170}{4} = \frac{8}{4} = 2$$



1 Section 7-2: Estimere populasjonsandelen

2 Section 7-4: Estimere μ når σ er ukjent

Kapittel 7

Nå begynner vi med statistisk inferens!

Bruke stikkprøven til å

- ① Estimere verdien til en parameter i populasjonen. (Kapittel 7)
- ② Teste en påstand/hypotese om en parameter i populasjonen
(Kapittel 8)

Hva skal vi estimere ?

- Populasjonsandelen p
- Populasjonsgjennomsnittet \bar{x}

Estimere populasjonsandelen

Konfidensintervall

- Vi ønsker å estimere andelen i populasjonen p
- Vi starter med andelen \hat{p} i stikkprøven og lager et konfidensintervall.

Forutsetninger for et riktig konfidensintervall

- Stikkprøven er et tilfeldig utvalg
- Betingelsen for en binomisk forsøksrekke holder (se seksjon 5-3)
- Minst 5 suksesser og 5 fiaskoer

Notasjon

Notasjon

- Andelen i populasjonen: p
(eng: proportion. Ikke forveksle med p i binomialfordelingen)
- Andelen i stikkprøven $\hat{p} = \frac{x}{n}$
 $n = 100 \text{ studenter}$
 $x = 21 \text{ har iPhone}$
 $\hat{p} = \frac{21}{100} = 0.21$
- x er antall suksesser i en stikkprøve med n objekter
- $\hat{q} = 1 - \hat{p}$ andelen fiaskoer

Forutsetninger for et riktig konfidensintervall for p

- Stikkprøven er et tilfeldig utvalg
- Betingelsen for en binomisk forsøksrekke holder (se seksjon 5-3)
 - I stikkprøven er minst 5 med i andelen, og minst 5 er ikke med

Punktestimat

Punktestimator

En punktestimator er en enkel verdi som anslår verdien til en parameter

Punktestimator for andelen ρ

$$\hat{\rho} = \frac{x}{n}$$
 er den beste punktestimatoren for ρ

Å estimere en parameter

- Du kan enten bruke et punktestimat
- Eller estimere parameteren med et intervall

Konfidensintervall

Konfidensintervall og konfidensnivå

Et *konfidensintervall* er et intervall som brukes til å estimere den sanne verdien til en populasjonsparameter.

Konfidensnivået angir hvor ofte intervallet faktisk vil inneholde den sanne populasjonsparametren. Til hvert konfidensnivå tilhører det en α

Konfidensnivå	α
90%	$\alpha = 0.10$
95 %	$\alpha = 0.05$
99 %	$\alpha = 0.01$

Example

Et 95% konfidensintervall vil 95% av gangene inneholde parameteren

Example

"Av 851 besøkende i et kjøpesenter har 51% jordbær som favorittsmak på is."

- Sjekk at forutsetningene på side 5
 - Punktestimatet for andelen er $\hat{p} = 0.51$
 - 95% konfidensintervall for andelen som foretrekker jordbær blir da
- $$\underbrace{< 0.476, 0.544 >}_{\text{fra } 51\% - 3.4\% \text{ til } 51\% + 3.4\%}$$
- Vi er 95% sikre på at intervallet fra 0.476 til 0.544 inneholder den sanne andelen av folk som foretrekker is med jordbærsmak.
 - Dette betyr at dersom vi spurte mange grupper av 829 personer, og lagde et konfidensintervall hver gang, så vil 95% av intervallene inneholde den sanne andelen p

Kritiske verdier $Z_{\alpha/2}$

95% konfidensnivå

$$\alpha = \underline{\underline{0.05}}$$


$$Z_{\alpha/2} = z_{0.025} = \underline{\underline{1.96}}$$

Prosedyren

Men hvordan fant man ut at intervallet går ifra 0.476 til 0.544?


Kritiske verdier

- Sjekk krav side 5 →
 \hat{p} normalfordelt.
- α blir da arealet i to haler
- Det gir kritiske verdier $Z_{\alpha/2}$




Found from
Table A-2

$Z_{\alpha/2} = \pm 1.96$ for 95% konfidensinterval



Bruk Table A-2 til å finne z verdien 1.96



Bruke $Z_{\alpha/2} = \pm 1.96$ til å finne feilmarginen

Estimatoren \hat{p} er normalfordelt

Når kravene på side 5 er tilfredstilt, så er \hat{p} er normalfordelt med forventning p og standardavvik $\sigma_{\hat{p}} = \sqrt{\hat{p}(1 - \hat{p})/n}$

Feilmarginen for konfidensintervallet for en andel

$$E = z_{\alpha/2} \cdot \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}$$

Example

Vi hadde $n = 821$ kunder med $\hat{p} = 0.51$, så da blir feilmarginen

$$E = 1.96 \cdot \sqrt{\frac{0.51(1 - 0.51)}{821}} = 0.034$$

Andel jordbær i konfidensintervall

Example

- ➊ Vi ville ha et 95% konfidensintervall
 - ➋ Vi fant kritisk verdi $z_{\alpha/2} = 1.96$
 - ➌ Andelen i stikkprøven var $\hat{p} = 0.51$
 - ➍ Regne ut feilmarginen $E = 0.034$
 - ➎ Konfidensintervallet blir da
- $$\hat{p} \pm E \leftrightarrow 0.51 \pm 0.034$$
- ➏ Fra $0.51 - 0.034$ til $0.51 + 0.034$
 - ➐ 95% konfidensintervall: Fra 0.476 til 0.544

Forskjellige måter å oppgi konfidensintervall på

Kjært barn har mange navn

$$0.476 < \rho < 0.544$$

$$0.51 \pm 0.034$$

$$< 0.476, 0.544 >$$

Konfidensintervall for andelen

Prosedyre

- 1 Sjekk at krav på side 5 OK
- 2 Finn kritisk verdi $z_{\alpha/2}$ i tabell A2
- 3 Regn ut feilmargin $E = z_{\alpha/2} \cdot \sqrt{\hat{p}(1 - \hat{p})/n}$
- 4 Regn ut nedre grense $\hat{p} - E$ og øvre grense $\hat{p} + E$
- 5 Rund av til tre desimaler
- 6 Oppgi konfidensintervallet

$$\hat{p} - E < p < \hat{p} + E$$