



## Statistisk inferens

En enkelt stikprøve og lineær regression

Stat. modeller, estimation og konfidensintervaller

Claus Ekstrøm

E-mail: ekstrom@life.ku.dk



## Gennemsnittet

Krabbedata:

- Interessen i den gennemsnitlige vægt i **populationen** —  $\mu$
- Har en **stikprøve** på 162 krabber:  $y_1, \dots, y_{162}$ .
- Stikprøvestørrelser,  $\bar{y} = 12.76$  og  $s = 2.25$ .
- Specielt,  $\hat{\mu} = \bar{y} = 12.76$

Men:

- Hvor meget kan stole på dette estimat? **Hvor præcist er det?**
- Hvad ville der ske hvis vi indsamlede 162 andre krabber?

Hvis vi bruger normalfordelingen, kan vi faktisk svare meget præcist på disse spørgsmål!

Vil lave **konfidensinterval for  $\mu$** . Dette kræver en **statistisk model**.




## Program

- Fordeling af gennemsnit
- Statistisk inferens for en enkelt stikprøve
  - statistisk model
  - estimation og præcision af estimer
  - $t$ -fordelingen
  - konfidensintervaller
- Statistisk inferens for lineær regression



## Fordeling af gennemsnit

Histogrammer over gennemsnit af  $n$  stk.  $N(0,1)$ -fordelte variable.



Middelværdi? — Spredning? — fordeling?



## Fordeling af gennemsnit

Husk fra sidst at sum af to normalfordelte variable og skalering af normalfordelte variable igen er normalfordelt.

Udvidelse til sum af  $n$  uafhængige  $N(\mu, \sigma^2)$ -variable:

- $y_1 + y_2 + \dots + y_n \sim N(n\mu, n\sigma^2)$
- $\bar{y} = \frac{1}{n}(y_1 + y_2 + \dots + y_n) \sim N(\mu, \sigma^2/n)$


Altså:  $\hat{\mu} = \bar{y}$  er normalfordelt med middelværdi  $\mu$  og spredning  $\sigma/\sqrt{n}$ .

Det fortæller os om variationen af  $\bar{y}$ !




## Statistisk model

Histogram og  $N$ -tæthed



QQ-plot



Statistisk model:  $y_1, \dots, y_{162}$  er uafhængige og  $y_i \sim N(\mu, \sigma^2)$

- Normalfordelt
- Alle  $y_i$  har samme middelværdi og samme spredning
- Uafhængighed — "deler ikke information"



## Den centrale grænseværdidisætning

Et af hovedresultaterne indenfor statistik og årsagen til at normalfordelingen er så pokkers vigtig.

### Den centrale grænseværdidisætning

Lad  $Y_1, \dots, Y_n$  være uafhængige variable med samme fordeling med middelværdi  $\mu$  og spredning  $\sigma$ . Så er

$$\bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i \sim N(\mu, \sigma^2/n)$$

Specielt

$$P\left(\frac{\bar{Y} - \mu}{\sigma/\sqrt{n}} \leq z\right) \rightarrow \Phi(z)$$



## Estimation

### Statistisk model:

$y_1, \dots, y_{162} \sim N(\mu, \sigma^2)$  uafhængige

### Parametre i modellen

- middelværdien  $\mu$  — gennemsnittet i populationen
- spredningen  $\sigma$  — spredningen i populationen

Estimation: populationsparametrene estimeres ved stikprøvestørrelserne.

- $\hat{\mu} = \bar{y}$  — det er faktisk LS estimate
- $\hat{\sigma} = s$



## Præcision af $\hat{\mu}$

Estimatet  $\hat{\mu}$  siger ikke noget om præcisionen. Men vi ved jo at

- $sd(\bar{y}) = \sigma / \sqrt{n}$
- $\bar{y}$  ligger i  $\mu \pm 1.96 \cdot \sigma / \sqrt{n}$  med 95% sandsynlighed.

så  $\bar{y}$  rammer rigtigt "i gennemsnit" og bliver mere og mere præcist jo større  $n$  bliver.

Åh-åh: kender ikke  $\sigma$  — kun estimatet  $s$ !

- Standard error af  $\bar{y}$  — estimeret spredning:

$$SE(\bar{y}) = s / \sqrt{n}$$

- $\bar{y}$  ligger i  $\mu \pm ??? \cdot s / \sqrt{n}$  med 95% sandsynlighed. Fraktilen skal ændres for at tage højde i usikkerheden i estimatet for  $\sigma$ .



## Skål

Øl




Gosset = Student



## $t$ -fordelingen

$df = 1, 4$  og  $N(0, 1)$



$t$ -fordelingen med  $n - 1$  frihedsgrader.

- Bredere haler end  $N(0, 1)$
- Ligner  $N(0, 1)$  mere og mere når  $df$  vokser

Standardisering

$$z = \frac{\sqrt{n}(\bar{y} - \mu)}{\sigma} \sim N(0, 1),$$

Fordelingen ændres hvis  $\sigma$  erstattes med  $s$ :

$$T = \frac{\sqrt{n}(\bar{y} - \mu)}{s} \sim t_{n-1}$$



## Konfidensinterval for $\mu$

Hvis  $t_{0.975, n-1}$  er 97.5%-fraktilen i  $t_{n-1}$ -fordelingen:

$$P\left(-t_{n-1, 0.975} < \frac{\sqrt{n}(\bar{y} - \mu)}{s} < t_{n-1, 0.975}\right) = 0.95.$$

Hvis vi flytter rundt og isolerer  $\mu$ :

$$P\left(\bar{y} - t_{n-1, 0.975} \cdot \frac{s}{\sqrt{n}} < \mu < \bar{y} + t_{n-1, 0.975} \cdot \frac{s}{\sqrt{n}}\right) = 0.95$$

Altså: intervallet

$$\bar{y} \pm t_{n-1, 0.975} \cdot \frac{s}{\sqrt{n}} \quad \text{eller} \quad \hat{\mu} \pm t_{n-1, 0.975} \cdot SE(\hat{\mu})$$

indeholder populationsmiddelværdien  $\mu$  med ssh. 95%.

Intervallet kaldes et 95% konfidensinterval for  $\mu$ .



## Konfidensintervaller: krabbedata

Husk:  $n = 162$ ,  $\bar{y} = 12.75$  og  $s = 2.25$ .

Fraktiler:

```
> qt(0.975,161)
[1] 1.974808
> qt(0.95,161)
[1] 1.654373
```


Beregn:

- Standard error,  $SE(\hat{\mu})$ ?
- 95% konfidensinterval?
- 90% konfidensinterval?

## Konfidensintervaller: fortolkning

Hvis vi gentog eksperimentet mange gange, så ville 95% af CI'erne indeholde populationsgennemsnittet.

Konfidensintervaller for 50 datasæt fra  $N(0,1)$ .



## Konfidensintervaller: fortolkning

95%-konfidensinterval for  $\mu$

$$\bar{y} \pm t_{n-1,0.975} \cdot \frac{s}{\sqrt{n}} = \hat{\mu} \pm t_{n-1,0.975} \cdot SE(\hat{\mu})$$

Fortolkning: intervallet indeholder med 95% sandsynlighed populationsgennemsnittet  $\mu$ .

- Hvordan beregnes et 90%-konfidensinterval? Bliver det bredere eller mindre?
- Hvad sker der hvis stikprøvestørrelsen  $n$  vokser? Bliver det tilsvarende konfidensinterval bredere eller mindre?

## Resumé: en stikprøve


- **Statistisk model:**  $y_1, \dots, y_{162}$  er uafhængige og  $y_i \sim N(\mu, \sigma^2)$
- **Parametre**,  $\mu$  og  $\sigma$ : gennemsnit og spredning i populationen
- **Estimater:**  $\hat{\mu} = \bar{y}$  og  $\hat{\sigma} = s$
- **Fordeling af estimat:**  $\hat{\mu}$  normalfordelt med middelværdi  $\mu$  og spredning  $\sigma/\sqrt{n}$
- **Standard error**, dvs. estimeret spredning for estimat:  $SE(\hat{\mu}) = s/\sqrt{n}$
- **95%-konfidensinterval:**  $\bar{y} \pm t_{n-1,0.975} \cdot \frac{s}{\sqrt{n}} = \hat{\mu} \pm t_{n-1,0.975} \cdot SE(\hat{\mu})$

Vi kan køre præcis de samme punkter igennem for lineær regression og ensidet variansanalyse (og mange andre modeller).


## Hvorfor skal vi lære om normalfordelingen (nu)?

Har set tre typer af data/eksperimenter med kontinuerte data:

### Ensidet ANOVA



### Lineær regression



En stikprøve:

Blood pressure							
96	119	119	108	126	128	110	105

Vi skal bruge normalfordelingen for alle tre forsøgstyper/datatyper!

## Estimation og fordeling af estimerater

Estimererne  $\hat{\beta}$  og  $\hat{\alpha}$  så I allerede i uge 1...

Estimat for spredning:

$$s = \sqrt{\frac{1}{n-2} \sum_{i=1}^n (y_i - \hat{\alpha} - \hat{\beta} \cdot x_i)^2} = \sqrt{\frac{1}{n-2} \sum_{i=1}^n r_i^2}$$

$\hat{\beta}$  og  $\hat{\alpha}$  er normalfordelte:

$$\hat{\beta} \sim N\left(\beta, \frac{\sigma^2}{SS_x}\right), \quad \hat{\alpha} \sim N\left(\alpha, \sigma^2 \left(\frac{1}{n} + \frac{\bar{x}^2}{SS_x}\right)\right), \quad SS_x = \sum_{i=1}^n (x_i - \bar{x})^2.$$

Igen: Estimerne rammer rigtigt i gennemsnit, med en præcision der vokser når  $n$  vokser.

## Statistisk model og parametre

Statistisk model: afvigelserne fra den rette linie er normalfordelt

$$y_i = \alpha + \beta \cdot x_i + e_i, \quad e_1, \dots, e_n \sim N(0, \sigma^2) \text{ uafhængige}$$

Antagelserne er:

- Alle  $y_i$  er normalfordelte
- Middelværdien af  $y_i$  er  $\alpha + \beta \cdot x_i$
- Alle  $y_i$  har samme spredning
- Uafhængighed

Parametre (populationsstørrelser)

- Skæring  $\alpha$  og hældning  $\beta$
- Spredning  $\sigma$  om den rette linie

## Standard errors og konfidensintervaller

Fordelinger:

$$\hat{\beta} \sim N\left(\beta, \frac{\sigma^2}{SS_x}\right), \quad \hat{\alpha} \sim N\left(\alpha, \sigma^2 \left(\frac{1}{n} + \frac{\bar{x}^2}{SS_x}\right)\right)$$

Standard errors — estimerede spredninger

$$SE(\hat{\beta}) = \frac{s}{\sqrt{SS_x}}, \quad SE(\hat{\alpha}) = s \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{SS_x}}$$

95% konfidensintervaller:

$$\hat{\beta} \pm t_{0.975, n-2} \cdot SE(\hat{\beta}), \quad \hat{\alpha} \pm t_{0.975, n-2} \cdot SE(\hat{\alpha})$$

Bemærk:  $t$ -fordelingen med  $n-2$  frihedsgrader — fordi der er 2 middelværdiparametre. Samme som nævner i formel for  $s$ ,  $df_e$ !

## Stearinsyredata

```
> model1 = lm(ford~ssyre)
> summary(model1)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	96.53336	1.67518	57.63	1.24e-10 ***
ssyre	-0.93374	0.09262	-10.08	2.03e-05 ***

Residual standard error: 2.97 on 7 degrees of freedom

Analyse:

- Statistisk model? Fortolkning af parametre?
- Estimater? Konfidensintervaller?



## Ordliste

Engelsk	Dansk
average/mean	gennemsnit
confidence interval	konfidensinterval
degrees of freedom (df)	frihedsgrader
least squares method	mindste kvadraters metode
sample	stikprøve
standard deviation (sd)	spredning
standard error (SE)	estimeret spredning for estimat"



## Dagens hovedpunkter

- Centrale grænseværdidisætning — hvorfor er den central?
- Statistisk model og parametre
- Estimater, fordeling af estimater, standard error
- Konfidensintervaller: estimat  $\pm t$ -fraktil  $\cdot$  SE(estimat) og **fortolkning**

