

# STK1100 våren 2023

## Konfidensintervaller

Svarer til avsnitt 8.1 i læreboka

Matematisk institutt  
Universitetet i Oslo

## Eksempel 1

En kjemiker er interessert i å bestemme konsentrasjonen  $\mu$  av et stoff i en løsning

Hun måler konsentrasjonen fem ganger med et bestemt apparat og får resultatene (i mg per liter):

2.52    2.49    2.62    2.45    2.56

Vi antar målingene hun får med apparatet er normalfordelte med forventningsverdi lik den sanne konsentrasjonen  $\mu$  (så det er ingen systematiske målefeil) og standardavvik  $\sigma = 0.10$

Et punktestimat for  $\mu$  er  $\bar{x} = 2.53$

Kan vi gi et intervall som med stor sikkerhet inneholder den virkelige konsentrasjonen?

## Generelt har vi følgende situasjon:

Observasjonene  $x_1, x_2, \dots, x_n$  er observerte verdier av stokastiske variabler  $X_1, X_2, \dots, X_n$  som er uavhengige og  $N(\mu, \sigma^2)$ -fordelte, der  $\sigma$  er kjent

Vi vil bestemme et intervall som med stor sikkerhet inneholder  $\mu$

Vi har at  $\bar{X} \sim N(\mu, \sigma^2 / n)$

Det følger at

$$Z = \frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \sim N(0, 1)$$

Vi har at

$$P(-1.96 \leq Z \leq 1.96) = 0.95$$

dvs

$$P\left(-1.96 \leq \frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \leq 1.96\right) = 0.95$$

Ved å omforme ulikhetene gir dette at

$$P\left(\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + 1.96 \frac{\sigma}{\sqrt{n}}\right) = 0.95$$

Så det **stokastiske** intervallet

$$\left(\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}}, \bar{X} + 1.96 \frac{\sigma}{\sqrt{n}}\right)$$

inneholder  $\mu$  med 95% sannsynlighet

Når vi setter inn de observerte verdiene  $x_1, x_2, \dots, x_n$  av de stokastiske variablene  $X_1, X_2, \dots, X_n$  får vi intervallet

$$\left( \bar{x} - 1.96 \frac{\sigma}{\sqrt{n}} , \bar{x} + 1.96 \frac{\sigma}{\sqrt{n}} \right)$$

Dette er et **95% konfidensintervall** for  $\mu$


I eksempel 1 får vi intervallet

$$2.53 \pm 1.96 \frac{0.10}{\sqrt{5}} \quad \text{dvs} \quad 2.53 \pm 0.09$$

Vi kan si at 0.09 er en **feilmargin** for estimatet

# Simulering av 50 konfidensintervaller

```
import numpy as np
import scipy.stats as stats
import math
import matplotlib.pyplot as plt
m=2.50
s=0.10
n=5
plt.xlim([m-0.25,m+0.25])
plt.ylim([0,50])
plt.plot([m,m],[0,50])
ind=np.arange(1,51)
for k in ind:
    x=stats.norm.rvs(size=n,loc=m,scale=s)
    low=np.mean(x)-1.96*s/np.sqrt(n)
    up=np.mean(x)+1.96*s/np.sqrt(n)
    plt.plot([low,up],[k,k])
```



Antall intervaller som inneholder den sanne verdien av  $\mu$  er binomisk fordelt med  $p = 0.95$

## Bredden av konfidensintervallet

Konfidensintervallet til kjemikeren var  $2.53 \pm 1.96 \frac{0.10}{\sqrt{5}}$

Bredden av intervallet er  $2 \cdot 1.96 \frac{0.10}{\sqrt{5}} = 0.175$


Hvor mange målinger må kjemikeren gjøre hvis hun ønsker at konfidensintervallet skal ha bredde 0.12?

Med  $n$  observasjoner blir bredden  $2 \cdot 1.96 \frac{0.10}{\sqrt{n}}$

Altså  $2 \cdot 1.96 \frac{0.10}{\sqrt{n}} \leq 0.12$

Det gir  $n \geq \left( \frac{2 \cdot 1.96 \cdot 0.10}{0.12} \right)^2 = 10.67$ , dvs 11 målinger

Det er vanlig å se på konfidensintervall med **konfidenskoeffisient** 90%, 95% eller 99%



Generelt er et  $100(1 - \alpha)\%$  konfidensintervall for  $\mu$  gitt ved

$$\left( \bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \quad \bar{x} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right)$$

eller kortversjonen  $\bar{x} \pm z_{\alpha/2} \sigma / \sqrt{n}$



## Eksempel 2

En annen kjemiker er interessert i å bestemme presisjonen til et apparat

Han bruker en standardløsning med kjent konsentrasjon  $\mu = 4.00$  og måler konsentrasjonen av denne seks ganger med apparatet og får resultatene

3.86 4.17 3.77 3.99 4.04 4.10

Vi antar som før at måleresultatene er normalfordelte, men nå er det  $\sigma$  som er ukjent mens  $\mu$  er kjent

Kan vi gi et estimat for  $\sigma$ ?

Kan vi gi et intervall som med stor sikkerhet inneholder den virkelige presisjonen  $\sigma$ ?

## Generelt har vi følgende situasjon:

Observasjonene  $x_1, x_2, \dots, x_n$  er observerte verdier av stokastiske variabler  $X_1, X_2, \dots, X_n$  som er uavhengige og  $N(\mu, \sigma^2)$ -fordelte, der  $\mu$  er kjent

$$\text{Vi har at } E\{(X_i - \mu)^2\} = V(X) = \sigma^2$$

En forventningsrett estimator for  $\sigma^2$  er

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$$

Estimator for  $\sigma$ :

$$\hat{\sigma} = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2}$$

I **eksempel 2** får vi estimatet  $\hat{\sigma} = 0.137$

For å finne et konfidensintervall, merker vi oss først at

$$Z_i = \frac{X_i - \mu}{\sigma} \sim N(0,1)$$

Det følger at  $Z_i^2 = \frac{(X_i - \mu)^2}{\sigma^2}$  er ki-kvadratfordelt

med 1 frihetsgrad, dvs. gamma-fordelt med  $\alpha = 1/2$  og  $\beta = 2$  (se side 261)

Hvis  $U$  og  $V$  er uavhengige og

$$U \sim \text{gamma}(\alpha_1, \beta) \quad V \sim \text{gamma}(\alpha_2, \beta)$$

så er


$$U + V \sim \text{gamma}(\alpha_1 + \alpha_2, \beta)$$

Det følger at

$$\sum_{i=1}^n Z_i^2 = \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \mu)^2 = \frac{n\hat{\sigma}^2}{\sigma^2} \sim \text{gamma}(n/2, 2)$$

dvs. ki-kvadratfordelt med  $n$  frihetsgrader

La  $\chi_{\alpha, \nu}^2$  være  $100(1-\alpha)\%$ -persentilen i kji-kvadratfordelingen med  $\nu$  frihetsgrader



Da har vi at

$$P\left(\chi_{0.975, n}^2 \leq \frac{n\hat{\sigma}^2}{\sigma^2} \leq \chi_{0.025, n}^2\right) = 0.95$$

Det gir

$$P\left(\frac{n\hat{\sigma}^2}{\chi_{0.025,n}^2} \leq \sigma^2 \leq \frac{n\hat{\sigma}^2}{\chi_{0.975,n}^2}\right) = 0.95$$

$$P\left(\sqrt{\frac{n}{\chi_{0.025,n}^2}} \hat{\sigma} \leq \sigma \leq \sqrt{\frac{n}{\chi_{0.975,n}^2}} \hat{\sigma}\right) = 0.95$$

95% konfidensintervall

$$\left[ \sqrt{\frac{n}{\chi_{0.025,n}^2}} \hat{\sigma} , \sqrt{\frac{n}{\chi_{0.975,n}^2}} \hat{\sigma} \right]$$

I **eksempel 2** får vi:

$$\left[ \sqrt{\frac{6}{14.45}} 0.137 , \sqrt{\frac{6}{1.237}} 0.137 \right] = [ 0.088 , 0.302 ]$$

# Generell framgangsmåte for konfidensintervall

Vi har stokastiske variabler  $X_1, X_2, \dots, X_n$

Vi vil bestemme et **100(1- $\alpha$ )% konfidensintervall** for en parameter  $\theta$

Anta at vi har en observator  $h(X_1, X_2, \dots, X_n, \theta)$  og at fordelingen til observatoren ikke avhenger av  $\theta$  eller noen andre parametere

Hvis vi lar  $a$  og  $b$  være henholdsvis

$100 \cdot (\alpha / 2)\%$ -persentilen og

$100 \cdot (1 - \alpha / 2)\%$ -persentilen i fordelingen til  $h(X_1, X_2, \dots, X_n, \theta)$ , så har vi at

$$P(a \leq h(X_1, X_2, \dots, X_n, \theta) \leq b) = 1 - \alpha$$

Anta nå at vi kan omforme ulikhetene:

$$a \leq h(X_1, X_2, \dots, X_n, \theta) \leq b$$



$$L(X_1, X_2, \dots, X_n) \leq \theta \leq U(X_1, X_2, \dots, X_n)$$

Da har vi at:

$$P(L(X_1, X_2, \dots, X_n) \leq \theta \leq U(X_1, X_2, \dots, X_n)) = 1 - \alpha$$


Når vi setter inn de observerte verdiene  $x_1, x_2, \dots, x_n$  av de stokastiske variablene  $X_1, X_2, \dots, X_n$ , får vi et  $100(1-\alpha)\%$  konfidensintervall for  $\theta$ :

$$[L(x_1, x_2, \dots, x_n), U(x_1, x_2, \dots, x_n)]$$

## Eksempel:

En har målt tiden mellom 800 impulser i en nervefiber  
(<http://www.statsci.org/data/general/nerve.html>)

Vi kan modellere nerveimpulsene som en Poissonprosess  
(jf. sidene 160-161). Tiden mellom to impulser er da  
eksponentialfordelt (jf. Side 235)



$$\bar{x} = 21.9 \quad (\text{enhet } 1/100 \text{ sekund})$$

Vi vil finne et 95% konfidensintervall for forventet  
tid mellom to nerveimpulser



## Generelt har vi følgende situasjon:

Observasjonene  $x_1, x_2, \dots, x_n$  er observerte verdier av stokastiske variabler  $X_1, X_2, \dots, X_n$  som er uavhengige og eksponentialfordelt, dvs de har tettheten (jf. side 198)

$$f(x, \lambda) = \begin{cases} \lambda e^{-\lambda x} & \text{for } x \geq 0 \\ 0 & \text{for } x < 0 \end{cases}$$

Vi vil finne et konfidensintervall for forventningsverdien  $\mu = 1/\lambda$


Vi finner først et konfidensintervall for  $\lambda$

Vi kan vise at  $Y_i = 2\lambda X_i$  er kji-kvadratfordelt med 2 frihetsgrader, dvs gamma-fordelt med  $\alpha = 2/2 = 1$  og  $\beta = 2$  (detaljer på forelesningen)

Det følger at 
$$\sum_{i=1}^n Y_i = 2\lambda \sum_{i=1}^n X_i = 2\lambda n\bar{X}$$

er kji-kvadratfordelt med  $2n$  frihetsgrader, dvs. gamma-fordelt med  $\alpha = 2n/2 = n$  og  $\beta = 2$

La  $\chi_{\alpha, \nu}^2$  være  $100(1 - \alpha)\%$ -persentilen i  $\chi^2$ -fordelingen med  $\nu$  frihetsgrader



Da har vi at

$$P\left(\chi_{0.975, 2n}^2 \leq 2\lambda n\bar{X} \leq \chi_{0.025, 2n}^2\right) = 0.95$$

Det gir

$$P\left(\frac{\chi_{0.975, 2n}^2}{2n\bar{X}} \leq \lambda \leq \frac{\chi_{0.025, 2n}^2}{2n\bar{X}}\right) = 0.95$$

Av dette får vi et 95% konfidensintervall for  $\lambda$

Forventningsverdien er gitt ved  $\mu = 1/\lambda$

Derfor er  $\lambda = 1/\mu$  og vi har at

$$P\left(\frac{\chi_{0.975,2n}^2}{2n\bar{X}} \leq \frac{1}{\mu} \leq \frac{\chi_{0.025,2n}^2}{2n\bar{X}}\right) = 0.95$$

Dette gir

$$P\left(\frac{2n\bar{X}}{\chi_{0.025,2n}^2} \leq \mu \leq \frac{2n\bar{X}}{\chi_{0.975,2n}^2}\right) = 0.95$$

Et 95% konfidensintervall for forventningsverdien er

$$\left[ \frac{2n\bar{x}}{\chi_{0.025,2n}^2}, \frac{2n\bar{x}}{\chi_{0.975,2n}^2} \right]$$

For nerveimpulsene har vi at  $n = 799$  og  $\bar{x} = 21.9$

Fra Python finner vi at

$$c_{0.975, 1598}^2 = 1489.1 \quad \text{kommando: stats.chi2.ppf(0.025, 1598)}$$

$$c_{0.025, 1598}^2 = 1710.7 \quad \text{kommando: stats.chi2.ppf(0.975, 1598)}$$

Et 95% konfidensintervall for forventet tid mellom to nerveimpulser er (målt i 1/100 sekunder)

$$\left[ \frac{2 \cdot 799 \cdot 21.9}{1710.7}, \frac{2 \cdot 799 \cdot 21.9}{1489.1} \right]$$

dvs

$$[20.5, 23.5]$$