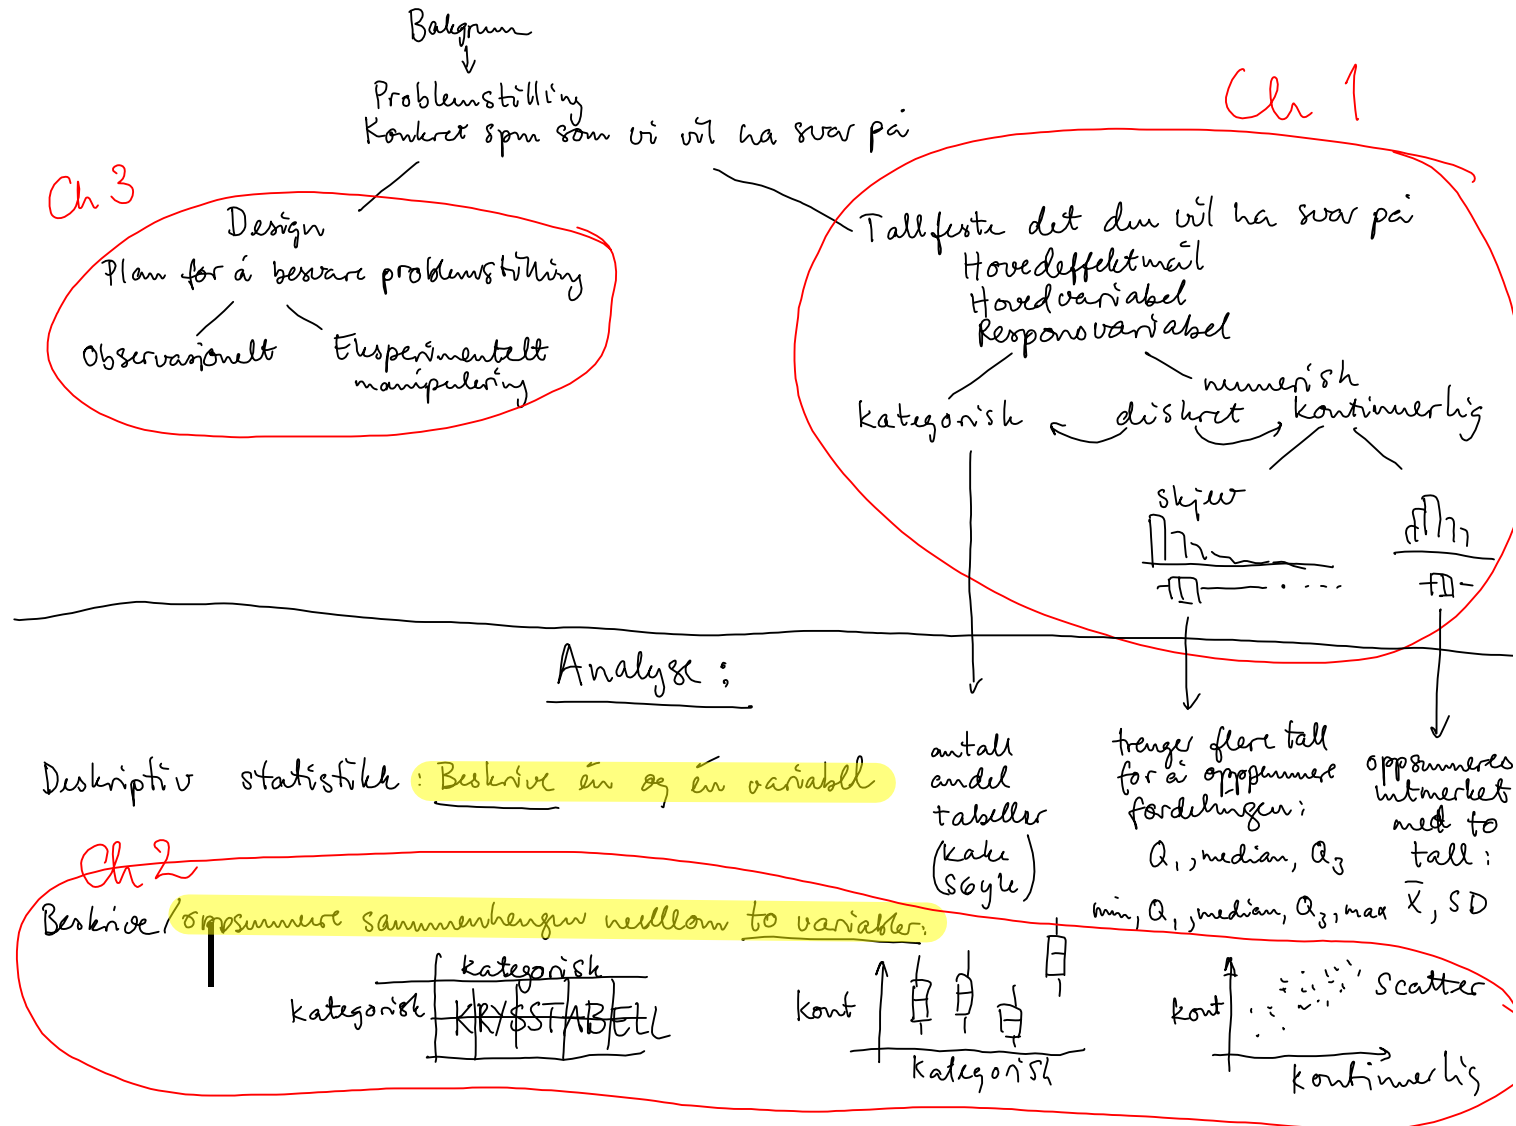


Tirsdag 18/10

OPPSUMMERING AV FØRSTE HALVDEL AV STR1000



>R      table (blodtype, yrke)      boxplot (løn ~ yrke)      plot (glukose, insulin)

Formalisering :

Sannsynlighet  
 Sannsynlighetsmodell  
 stokastisk / random / tilfeldig variabel  $X$   
 $X$  har et sett med verdier den kan være, og en sh fordeling

Ch 4

$x$		
$P(X=x)$		1

$E(x)$  ,  $Var(x)$  ,  $\sigma_x = \sqrt{Var(x)}$

Populasjon & parameter

vs

Utvalg & statistic observator

$\infty$

$n$

$\mu$   
 $p$

$\bar{x}$   
 $\hat{p}$  } fordelingen til  $\bar{x}$ , og til  $\hat{p}$

Ch 5

RESTEN AV STR1000

Uke 42 Estimering, inklusive konfidensintervall  
for  $\mu$   
for  $p$  } Ch 5 + Ch 6.1

Uke 43 Hypotestesting  
Sammenlign grupper og finne sammenhenger mellom  
to variabler: Bivariate tester

Tabellanalyse Ch 9 ikke pinner	t-test Ch 7.2	korrelasjon Ch 2.3
	Mann-Whitney test Ch 15.1	

> R

Uke 44 Mer estimering & hypotestesting  
Etttrialgtester } Ch 7.1  
parere tester

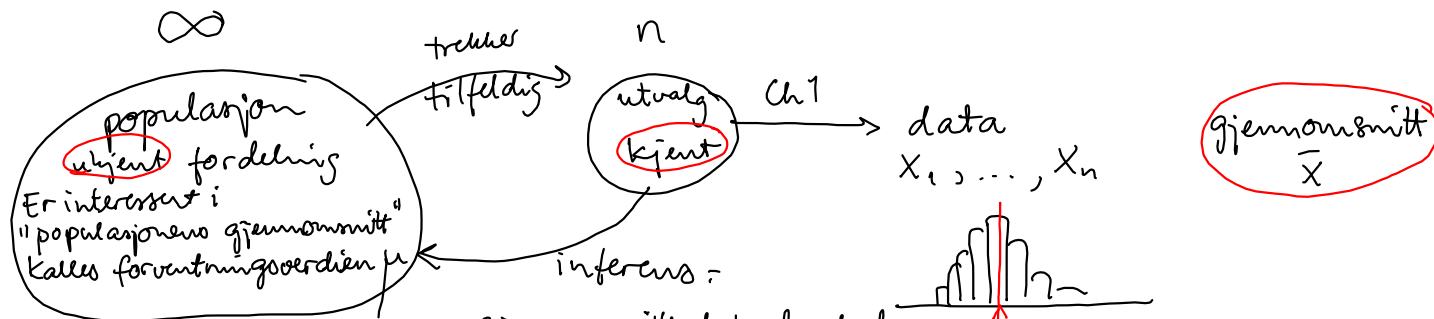
Uke 45 Regresjon = Ch 2.4 + 2.5 + Ch 10.1

> R

Uke 46 Mer regresjon! Ch 10.1 + Ch 11 Forklaring vs prediksjon  
> R


Uke 47 Repetisjon

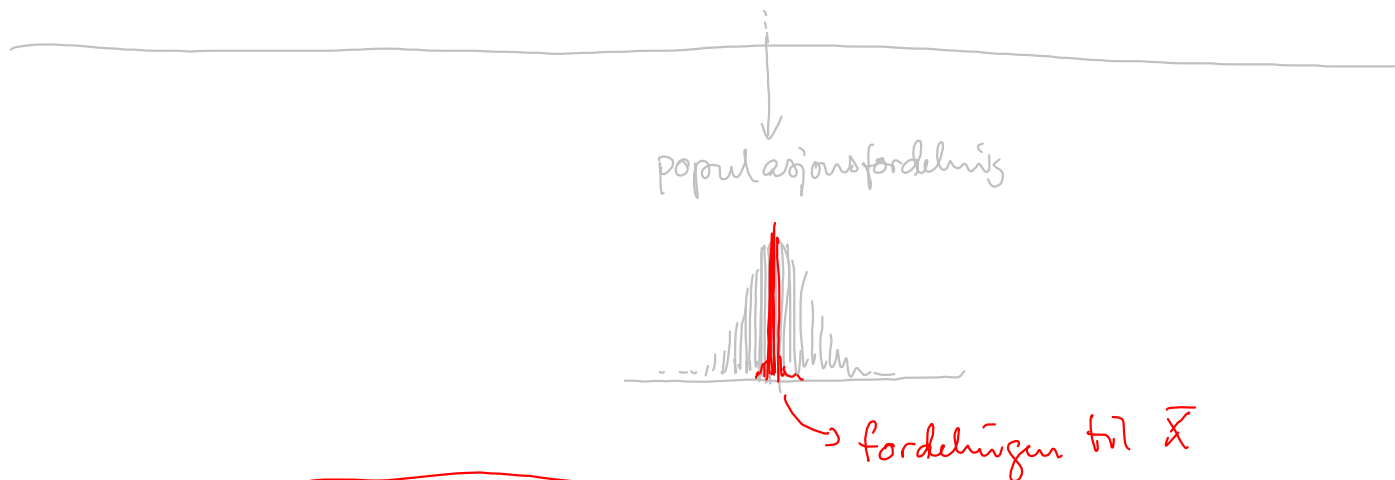
Estimering og konfidensintervall ← trenger å vite noe om fordelingen til estimatoren



inferens:  
 gjennomsnittet i utvalget  
 ligner på gjennomsnittet i  
 populasjonen:  $\bar{x} \approx \mu$


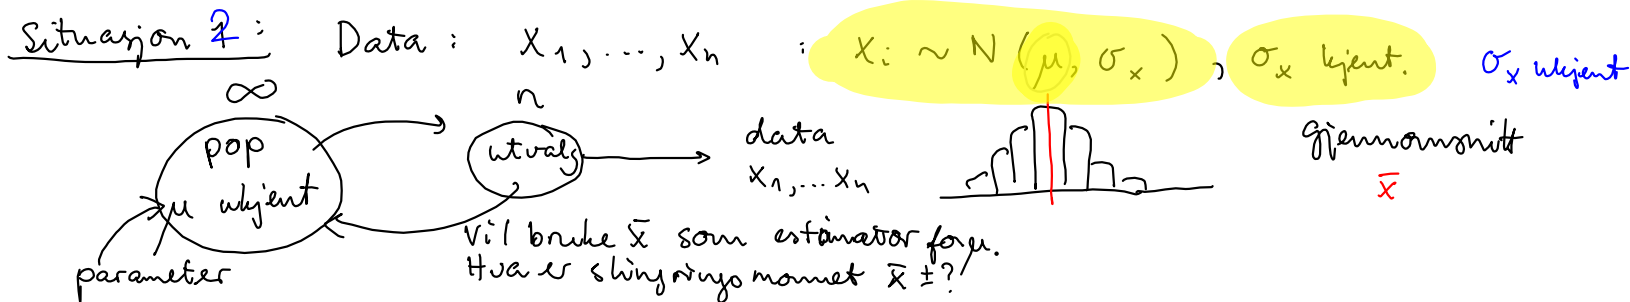
$\bar{x}$  er et estimat for  $\mu$ . Men det er ikke nødvendigvis like  $\mu$ :  $\bar{x} \pm ?$   
 Hvor stort slingsingsrom? Dette uttrykker vi presist med et  
 konfidensintervall. For at vi skal kunne lage et konf. int, må vi  
 tenke oss:





Fordelingen til  $\bar{x}$  er den vi bruker når vi skal regne ut et konfidensintervall.

Hvordan denne ser ut avhenger av hvilken fordeling dataene har (er de normalfordelte eller ikke, og er  $\sigma$  for dataene kjent eller ikke), og av hvor stor  $n$  er.



Når, må estimere  $\sigma_x$ , bruker  $s_{dx}$  i stedet.

$$\bar{X} \sim N\left(\mu, \frac{\sigma_x}{\sqrt{n}}\right) \rightarrow Z = \frac{\bar{x} - \mu}{\frac{\sigma_x}{\sqrt{n}}} \sim N(0, 1)$$

Når  $\sigma_x$  ukjent: ikke sann, det er mer usikkerhet inn i bildet

$$t = \frac{\bar{x} - \mu}{\frac{s_{dx}}{\sqrt{n}}} \sim T_{n-1}$$

$T_{00} = N(0, 1)$

$T_4$

Eksempel:

$X_1, \dots, X_{25}$  IQ målinger; STK1000  $\sigma = 15$



$\approx N$ -fordelt,  $\sigma$  kjent.  $n = 25$ ,  $\bar{X} = 110$

Estimat for  $\mu$ , forventet IQ for statistikkstudenter:  $\bar{X}$

$\bar{X}$  er estimator for  $\mu$

Estimat for  $\mu$ : 110

95% Konfidensintervall for  $\mu$ :  $\bar{X} \pm 1.96 \cdot \frac{\sigma}{\sqrt{n}}$  :  $110 \pm 1.96 \cdot \frac{15}{5}$   
 90%  $\underbrace{\hspace{10em}}_{1.645}$

Men hva hvis  $\sigma =$  ukjent?  
 sd = 14.3

Data  $\sim N$ ,  $n = 25$ : Situasjon 2

$\frac{\bar{X} - \mu}{\frac{sd}{\sqrt{n}}} \sim T_{n-1}$   
 $25-1=24$   
 Table D  $df = 24$   $\rightarrow$  upper-tail 0.025  $\rightarrow$  2.064

95% konfidensintervall  
 $\rightarrow 110 \pm 2.064 \cdot \frac{14.3}{5}$