

# Kursus 02323: Introducerende Statistik

## Forelæsning 12: Forsøgsplanlægning

Peder Bacher

DTU Compute, Dynamiske Systemer  
Bygning 303B, Rum 010  
Danmarks Tekniske Universitet  
2800 Lyngby – Danmark  
e-mail: pbac@dtu.dk

Spring 2023

## Afsnit 3.3 og 7.2.2: Forsøgsplanlægning

Grundlæggende koncepter for forsøgsplanlægning:

- Testens styrke er  $1 - \beta$  (*hvor  $\beta$  er sandsynligheden for at begå Type II fejl*)

Specifikke metoder, forsøgsplanlægning  
(middelværdi, både one og two sample setup):

- Stikprøvestørrelse  $n$  for ønsket præcision af konfidensintervaller
- Stikprøvestørrelse  $n$  for ønsket styrke af tests

Specifikke metoder, forsøgsplanlægning  
(andel, one sample setup):

- Stikprøvestørrelse  $n$  for ønsket præcision af konfidensintervaller

## Section 3.3 and 7.2.2: Design of experiments

General concepts for design of experiments:

- Power of a test is  $1 - \beta$  (*where  $\beta$  is the probability of making a Type II error*)

Specific methods, design of experiments  
(mean, both one and two sample setup):

- Sample size  $n$  for wanted precision of confidence intervals
- Sample size  $n$  for wanted power of tests

Specific methods, design of experiments  
(proportion, one-sample setup):

- Sample size  $n$  for wanted precision of confidence intervals

# Oversigt

- 1 Planlægning af studie med krav til præcision
- 2 Planlægning: Power og sample size
- 3 Andele: Bestemmelse af stikprøvestørrelse

# Planlægning af studie med krav til præcision

Man vil gerne tænke sig om inden eksperimentet udføres:

- Brug for at vide hvor præcise resultater (f.eks. konfidensinterval) forventes at blive med et fremtidigt eksperiment
- Hvor stor en effekt forventes at kunne opdages (e.g. hvis sovemedicinen virker 2 timer bedre, hvad er sandsynligheden for at det opdages?)
- Spørgsmål om at optimere økonomiske ressourcer og etik!

## Method 3.63: The one-sample CI sample size formula

Antal observationer og den forventede (halve) bredde af konfidensintervallet

When  $\sigma$  is known or guessed at some value, we can calculate the sample size  $n$  needed to achieve a given margin of error,  $ME$ , with probability  $1 - \alpha$  as

$$n = \left( \frac{z_{1-\alpha/2} \cdot \sigma}{ME} \right)^2$$

- Margin of error  $ME$  er den *halve bredde* af konfidensintervallets forventede bredde

# Eksempel på to mulige fejl ved hypotesetest – sovemedicin

To mulige sandheder vs. to mulige konklusioner:

<i>Test udfald</i>		
<i>Virkelighed</i>	<b>Afvis <math>H_0</math></b>	<b>Afvis ikke <math>H_0</math></b>
<b>Sand <math>H_0</math>:</b> Medicinen virker ikke	Type I fejl ( $\alpha$ )	Korrekt: Ingen effekt
<b>Falsk <math>H_0</math>:</b> Medicinen virker	Korrekt: Påvist effekt	Type II fejl ( $\beta$ )

# Eksempel på to mulige fejl ved hypotesetest (repetition)

To mulige sandheder vs. to mulige konklusioner:

<i>Test udfald</i>		
<i>Virkelighed</i>	<b>Afvis <math>H_0</math></b>	<b>Afvis ikke <math>H_0</math></b>
<b>Sand <math>H_0</math></b>	Type I fejl ( $\alpha$ )	Korrekt accept af $H_0$
<b>Falsk <math>H_0</math></b>	Korrekt afvisning af $H_0$	Type II fejl ( $\beta$ )



## Mulige fejl ved hypotesetests (repetition)

Der findes to slags fejl (dog kun een af gangen!)

Type I: Rejection of  $H_0$  when  $H_0$  is true

(Medicinen virker ikke, men vi kommer til at tro den virker)

Type II: Non-rejection of  $H_0$  when  $H_1$  is true

(Medicinen virker, men vi opdager det ikke)

Risikoen for de to typer fejl kaldes sædvanligvis:

$$P(\text{Type I error}) = \alpha$$

$$P(\text{Type II error}) = \beta$$

# Testens styrke (power)

Hvad er styrken  $1 - \beta$  for et kommende studie/eksperiment:

- Sandsynligheden for at opdage en effekt (af en vis størrelse  $|\mu_0 - \mu_1|$ )
- Probability of correct rejection of  $H_0$


Udfordring: Nulhypotesen kan være forkert på mange måder!

I praksis, scenarie-baseret approach:

- F.eks. " Hvis nu sovemedicinen *rent faktisk virker 2 timer bedre*, hvor godt vil mit studie være til at opdage dette? "
- Eller, jeg vil gerne *hvis min sovemedicin virker 3 timer bedre*, opdage dette med en bestemt sandsynlighed (power)

$\bar{X} \sim N(\mu_1, \frac{\sigma^2}{n})$  er den antagede fordeling (dvs. om  $\mu_1$  og  $ME = |\mu_1 - \mu_0|$ )  
 $H_0 : \mu = \mu_0$  er nulhypotesen

Vi kan se hvad  $\beta$  er:  $P(H_0 \text{ accepteres forkert}) = P(\text{Type II}) = \beta$




## Spørgsmål om power (socrative.com - ROOM:PBAC)

Vi antager at  $\bar{X} \sim N(\mu_1, \frac{\sigma^2}{n})$  (dvs. fordelt om  $\mu_1$ , som er effekten vi vil kunne påvise),  $H_0 : \mu = \mu_0$  er nulhypotesen

Hvordan kan vi opnå en større power uden at kompromitere noget ved testen (dvs. ikke ændre på hypotesen eller risikoen for type I fejl)?

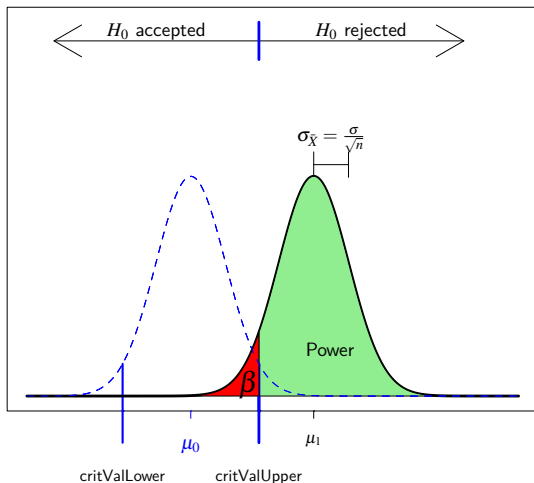
- A: Mindske  $\mu_0$  så  $ME = |\mu_0 - \mu_1|$  øges
- B: Øge  $\alpha$  (på figur vil 'critvalUpper' mindskes)
- C: Øge  $n$  antallet af observationer
- D: Desværre kan det ikke lade sig gøre
- E: Ved ikke

Svar C: Hvis antallet af observationer øges så stiger power uden at kompromitere andet ved testen



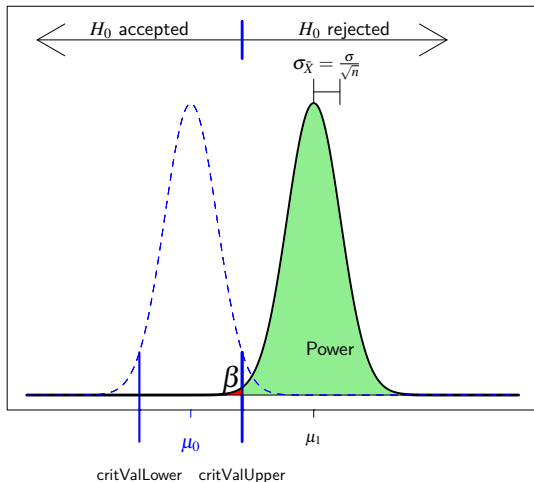
Vi antager  $\bar{X} \sim N(\mu_1, \frac{\sigma^2}{n})$  (dvs. fordelt om  $\mu_1$ , som er effekten vi vil kunne påvise),  $H_0 : \mu = \mu_0$  er nulhypotesen

Flere observationer, dvs. større  $n$



Vi antager  $\bar{X} \sim N(\mu_1, \frac{\sigma^2}{n})$  (dvs. fordelt om  $\mu_1$ , som er effekten vi vil kunne påvise),  $H_0 : \mu = \mu_0$  er nulhypotesen

Endnu flere observationer, dvs. endnu større  $n$



## Planlægning, find sample size $n$

Det store spørgsmål i praksis: HVAD skal  $n$  være?

Forsøget skal være stort nok til at kunne opdage en relevant effekt med stor power (som regel mindst 80%):

Metode 3.65: Tilnærmet svar for en one-sample  $t$ -test:

For the one-sample  $t$ -test for given  $\alpha$ ,  $\beta$  and  $\sigma$

$$n = \left( \sigma \frac{z_{1-\beta} + z_{1-\alpha/2}}{(\mu_0 - \mu_1)} \right)^2$$

where  $\mu_0 - \mu_1$  is the difference in means that we would want to detect and  $z_{1-\beta}$ ,  $z_{1-\alpha/2}$  are quantiles of the standard normal distribution.

# Planlægning, sæt 4 prm. og beregn den sidste

Når man har fastlagt hvilket test, der skal bruges:

Kender man (eller fastlægger/gætter på) fire ud af følgende fem oplysninger, kan man regne sig frem til den femte:

$n$  Sample size

$\alpha$  Significance level of the test

$\delta$  A difference in mean that you would want to detect (effect size)  
(dvs.  $\mu_2$  er her den middelværdi med afstand til  $\mu_1$  som vi "mindst" vil kunne påvise)

$\sigma$  The population standard deviation

$1 - \beta$  The power



# Eksempel - The sample size for power= 0.80

```
## Stikprøvestørrelse for t-test
power.t.test(power = .80, delta = 4, sd = 12.21, sig.level=0.05,
             type = "one.sample")

##
##      One-sample t test power calculation
##
##              n = 75.08
##             delta = 4
##              sd = 12.21
##      sig.level = 0.05
##              power = 0.8
##      alternative = two.sided
```

Svar:  $n = 76$  (*husk at runde op*)

### Metode 3.65: *Tilnærmet* svar for en one-sample $t$ -test:

Formlen giver lidt lavere resultat, fordi normalfordelingen bruges i stedet for  $t$ -fordelingen:

$$\begin{aligned}n &= \left( \sigma \frac{z_{1-\beta} + z_{1-\alpha/2}}{(\mu_0 - \mu_1)} \right)^2 \\ &= \left( 12.21 \frac{0.84 + 1.96}{4} \right)^2 \\ &= 73.05\end{aligned}$$

*I opgaver bruges resultatet fra `power.t.test()`, hvis der ikke henvises konkret til formelen fra bogen.*

# Eksempel - The power for $n = 40$

```
## Beregn power for t-test
power.t.test(n = 40, delta = 4, sd = 12.21, sig.level=0.05,
             type = "one.sample")

##
##      One-sample t test power calculation
##
##              n = 40
##             delta = 4
##             sd = 12.21
##      sig.level = 0.05
##             power = 0.5242
## alternative = two.sided
```

# Styrke og stikprøvestørrelse - two-sample

Finding the sample size for detecting a group difference of 2 with  $\sigma = 1$  and power = 0.9:

```
## Beregn stikprøvestørrelsen
power.t.test(power = 0.90, delta = 2, sd = 1, sig.level = 0.05)

##
##      Two-sample t test power calculation
##
##              n = 6.387
##              delta = 2
##              sd = 1
##              sig.level = 0.05
##              power = 0.9
##              alternative = two.sided
##
## NOTE: n is number in *each* group
```

Svar:  $n = 7$  (husk at runde op)

# Styrke og stikprøvestørrelse - two-sample

Finding the power of detecting a group difference of 2 with  $\sigma = 1$  for  $n = 10$ :

```
## Power beregning
power.t.test(n = 10, delta = 2, sd = 1, sig.level = 0.05)

##
##      Two-sample t test power calculation
##
##              n = 10
##             delta = 2
##              sd = 1
##      sig.level = 0.05
##             power = 0.9882
## alternative = two.sided
##
## NOTE: n is number in *each* group
```

# Styrke og stikprøvestørrelse - two-sample

Finding the detectable effect size ( $\delta$ ) with  $\sigma = 1$ ,  $n = 10$  and power = 0.9:

```
## Beregn margin of error
power.t.test(power = 0.90, n = 10, sd = 1, sig.level = 0.05)

##
##      Two-sample t test power calculation
##
##              n = 10
##             delta = 1.534
##              sd = 1
##      sig.level = 0.05
##              power = 0.9
## alternative = two.sided
##
## NOTE: n is number in *each* group
```

# Andele: Stikprøvestørrelse: "Margin of Error" (ME):

Margin of Error på estimat kan siges at være:

- Forventningsværdi af "halvdelen af konfidensintervallets bredde"
- "Den forskel i middelværdi" man gerne vil være i stand til at påvise
- Under  $H_0$ : Forventningsværdi af afstanden mellem middelværdien og det kritiske niveau

Margin of Error

med  $(1 - \alpha)\%$  konfidens bliver

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

hvor et estimat af  $p$  fås ved  $p = \frac{x}{n}$

## Spørgsmål om Margin of Error ([socratic.com](https://socratic.com), ROOM: pbac)

Hvad er "Margin of Error" (ME) hvis man vil have et konfidensinterval med bredde på 0.2?

- A: 0.1
- B: -0.15
- C: 0.2
- D: 0.4
- E: Ved ikke

Svar: A. ME er forventningsværdi af "halvdelen af konfidensintervallets bredde"



## Spørgsmål om forskel i middel ([socrative.com](https://socrative.com), ROOM: pbac)

Hvad er "Margin of Error" (ME) hvis man vil være i stand til at påvise forskel i middelværdi på 0.2?

- A: 0.1
- B: -0.15
- C: 0.2
- D: 0.4
- E: Ved ikke

Svar: C. "Den forskel i middelværdi" man gerne vil være i stand til at påvise

# Bestemmelse af stikprøvestørrelse

## Method 7.13

Såfremt man højst vil tillade en Margin of Error ( $ME$ ) med  $(1 - \alpha)\%$  konfidens, bestemmes den nødvendige stikprøvestørrelse ved

$$n = p(1 - p) \left[ \frac{z_{1-\alpha/2}}{ME} \right]^2$$

## Method 7.13

Såfremt man højst vil tillade en Margin of Error  $ME$  med  $(1 - \alpha)\%$  konfidens, og  $p$  ikke kendes, bestemmes den nødvendige stikprøvestørrelse ved

$$n = \frac{1}{4} \left[ \frac{z_{1-\alpha/2}}{ME} \right]^2$$

idet man får den mest konservative stikprøvestørrelse ved at vælge  $p = \frac{1}{2}$

## Eksempel 1 - fortsat

Venstrehåndede:

Antag vi ønsker  $ME = 0.01$  (med  $\alpha = 0.05$ ) - hvad skal  $n$  være?

Antag  $p \approx 0.10$ :

$$n = 0.1 \cdot 0.9 \left( \frac{1.96}{0.01} \right)^2 = 3467.4 \approx 3468$$

UDEN antagelse om størrelsen af  $p$ :

$$n = \frac{1}{4} \left( \frac{1.96}{0.01} \right)^2 = 9604$$

## Spørgsmål om stikprøvestørrelse (socrative.com, ROOM: pbac)

Ved test af hvilken af følgende nulhypoteser skal bruges den største stikprøvestørrelse ( $n$ ) ved samme  $\alpha$  signifikansniveau?

- A:  $H_0 : p = 0.2$
- B:  $H_0 : p = 0.1$
- C:  $H_0 : p = 0.4$
- D:  $H_0 : p = 0.95$
- E: Ved ikke

Svar: C. Jo tættere på  $p = 0.5$  man kommer jo højere  $n$

## Spørgsmål om stikprøvestørrelse ([socrative.com](https://socrative.com), ROOM: pbac)

Kan I nu beregne hvor mange gange man skal slå med en terning for at teste om den har sandsynlighed  $1/6$  indenfor  $0.01$  for at slå en sekser?

- A: Ja
- B: Nej
- C: Ved ikke

Svar: Ja, det har vi lige lært, så i R:

```
## Andel (sandsynlighed) vi vil teste for
p <- 1/6
## Signifikansniveau
## (hvor ofte vil vi lave denne fejl: Terningen er fair, men
## vi konkluderer den ikke er fair)
alpha <- 0.05
## Fejlmargen vi vil tillade
ME <- 0.01
## Beregn antal gange vi skal slå med terningen
p * (1-p) * (qnorm(1-alpha/2)/ME)^2

## [1] 5335
```

Husk også at sige at Exercise 3.10 spørgsmål c) er ret abstrakt og man kan springe den over.