

# TMA4240 Statistikk H2016 [22]: Hypotesetesting

Hypotesetesting

Tosidig test vs. konfidensintervall [10.4]

P-verdimetoden [10.3]

Ensidig test for ett normalfordelt utvalg [10.4]

To normalfordelte utvalg [10.5]

Mette Langaas

Institutt for matematiske fag, NTNU

[wiki.math.ntnu.no/emner/tma4240/2016h/start/](http://wiki.math.ntnu.no/emner/tma4240/2016h/start/)

# Hypotese

- ▶ En **statistisk hypotese** er et utsagn om egenskaper til en (eller flere) populasjone(r).
- ▶ **Nullhypotese:** Hypotesen vi vil undersøke om vi har grunnlag fra data til å forkaste.
- ▶ **Alternativ hypotese:** Reflekterer spørsmålet vi stiller (eller påstanden vi kommer med).

## To typer feil

- ▶ **DEF 10.2:** Forkasting av nullhypotesen når denne er sann, kalles en type-I-feil.
- ▶ **DEF 10.3:** Å ikke forkaste nullhypotesen når den er gal, kalles en type-II-feil.

|                | $H_0$ sann  | $H_0$ falsk  |
|----------------|-------------|--------------|
| Aksepter $H_0$ | Korrekt     | Type-II feil |
| Forkast $H_0$  | Type-I feil | Korrekt      |



<http://www.pitt.edu/upjecon/MCG/STAT/DeadlySins.jpg>

# Hypothesis test and legal trial

Legal trial:

- ▶  $H_0$ : The defendant is innocent.
- ▶  $H_1$ : The defendant is guilty.

Type I and Type II errors:

- ▶ Type I error: Miscarriage of justice, convict an innocent.
- ▶ Type II error: not convicting a guilty defendant.

The null- and alternative hypotheses are not commutable - they are handled differently. If we experience doubt we accept the null hypothesis.

## Type-I, Type-II and Power

|             | Not reject $H_0$ | Reject $H_0$ |
|-------------|------------------|--------------|
| $H_0$ true  | Correct          | Type I error |
| $H_0$ false | Type II error    | Correct      |

- ▶ Two sources of error: false positive rate  $\alpha$  and false negative rate  $\beta$ .
  - ▶ False positives = type I error.
  - ▶ False negatives = type II error.
- ▶ Power of a test: Ability to detect that the null hypothesis is false ( $1-\beta$ ).

## Ett utvalg: tosidig test for $\mu$ med $\sigma$ kjent

- ▶  $X_1, X_2, \dots, X_n$  u.i.f. normal( $\mu, \sigma$ ) der  $\sigma$  er kjent.
- ▶ To-sidig test:
  1.  $H_0 : \mu = \mu_0$  vs.  $H_1 : \mu \neq \mu_0$
  2. Signifikansnivå  $\alpha$  bestemmes.
  3. Testobservator under  $H_0$  er  $Z_0$ .  $Z_0 = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}}$  er under  $H_0$  standard normalfordelt.  
Forkast  $H_0$  hvis  $|Z_0| > z_{\frac{\alpha}{2}}$ .
  4. Beregn  $\bar{x}$  fra utvalget, og videre  $z_0 = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}}$ .  
Sammenlign  $z_0$  og  $z_{\frac{\alpha}{2}}$ , og forkast  $H_0$  hvis  $|z_0| > z_{\frac{\alpha}{2}}$ .

## Tosidig hypotesetest vs. konfidensintervall

$$H_0 : \mu = \mu_0 \quad \text{vs.} \quad H_1 : \mu \neq \mu_0$$

- ▶ Hvis et  $(1 - \alpha)100\%$  konfidensintervall **inneholder**  $\mu_0$  vil vi med en tosidig hypotesetest med signifikansnivå  $\alpha$  **ikke forkaste**  $H_0$  på nivå  $\alpha$ .
- ▶ Hvis et  $(1 - \alpha)100\%$  konfidensintervall **ikke inneholder**  $\mu_0$  vil vi med en tosidig hypotesetest med signifikansnivå  $\alpha$  **forkaste**  $H_0$  på nivå  $\alpha$ .



## Skriftlig øving 3, oppgave 1c: Marsvin og C-vitamin

Tilskudd 1:  $X_1, X_2, \dots, X_{n_1} \sim N(\mu, \sigma^2)$  angir odontoblastlengdene til et tilfeldig utvalg av  $n_1 = 10$  marsvin.

Tilskudd 2:  $Y_1, Y_2, \dots, Y_{n_2} \sim N(\eta, \tau^2)$  angir odontoblastlengdene til et tilfeldig utvalg av  $n_2 = 10$  marsvin.

Forskerne vil gjerne se på forskjellene de to tilskuddene har på differansen i forventet odontoblastlengde. Definer  $\delta = \mu - \eta$  som differansen mellom forventet odontoblastlengde for de to tilskuddene.

Fant 95% konfidensintervall til  $[1.66, 8.71]$ ,

Er det grunn til å tro at de to tilskuddene har ulik effekt på forventet odontoblastlengde? (Dette spørsmålet skal vi jobbe mer med videre i kurset, men du skal her basere svaret ditt på konfidensintervallet du har laget.)

$\mu_0 = 0$  er ikke i 95% konfidensintervallet og dermed ville vi forkaste  $H_0$  med signifikansnivå 5% ( $\alpha = 0.05$ ).

## $P$ -verdi [10.3]

**DEF 10.5:** En  $P$ -verdi er det laveste nivået hvor den observerte verdien til testobservatoren er signifikant.

**Utregning:**  $P$ -verdi =  $P(\text{for det vi har observert eller noe verre} \mid H_0 \text{ er sann})$

- Steg:**
- ▶ Bestem null- og alternativ hypotese.
  - ▶ Velg testobservator.
  - ▶ Beregn  $P$ -verdien basert på testobservatoren.
  - ▶ Bestem om vi vil forkaste eller beholde nullhypotesen basert på  $P$ -verdien og kunnskap om systemet.

**Tilleggsinformasjon:** Kan også gjøre hypotesetesting basert på signifikansnivå og forkastningsregion og oppgi  $P$ -verdi som tilleggsinformasjon.

## Vil pedikyrbehandling påvirke målt kroppsfettprosent?

Skriver ned null og alternativ hypotese, forklar hva utskriften sier.  
Velg signifikansnivå 5% og konkluder.

```
length(diff) = 40
mean(diff)   = 0.2975
std(diff)    = 1.1002

[h,p,ci,stats]=ttest(diff)
h =          0
p =         0.0952
ci =
  -0.0544
   0.6494
stats =
  tstat: 1.7101
    df: 39
    sd: 1.1002
tcdf(1.73,39,'upper')=0.0458
```

## Kropps fettprosent og pedikyr

$$H_0 : \mu = 0 \text{ mot } H_1 : \mu \neq 0$$

Vi antar at testobservatoren som brukes er t-fordelt

$$T_0 = \frac{\bar{D} - 0}{S \sqrt{\frac{1}{n}}}$$

$$t_0 = \frac{0.3 - 0}{1.10 \sqrt{\frac{1}{40}}} = 1.73$$

Hvis signifikansnivå 5%: Kritisk verdi finnes fra t-fordelingen med  $n - 1 = 40 - 1 = 39$  frihetsgrader, tabellen:  $t(0.025, 35) = 2.03$ , siden vi har en tosidig test. Vi forkaster  $H_0$  når  $t_0 \geq 2.03$  eller når  $t_0 \leq -2.03$ . Vi har observert at  $t_0 = 1.73$ , og dermed vil vi ikke forkaste nullhypotesen.

## Kropps fettprosent og pedikyr

$$H_0 : \mu = 0 \text{ mot } H_1 : \mu \neq 0$$

$P$ -verdi er  $2 \cdot P(T > 1.73) = 2 \cdot 0.0458 = 0.0916$ .

Med signifikansnivå 5% er  $p$ -verdien større enn valgt signifikansnivå, og vi forkaster ikke nullhypotesen.

Konklusjon: Vi forkaster ikke nullhypotesen og har ikke tilstrekkelig grunnlag til å si at pedikyrbehandlingen har noen effekt på måling av kropps fettprosent.

## $P$ -verdi

- ▶  $P$ -verdien gir sannsynligheten for å observere det vi har gjort, eller noe mer ekstremt (i retning  $H_1$ ) når nullhypotesen er sann.
- ▶  $P$ -verdien er *ikke* sannsynligheten for at nullhypotesen er sann (dessverre ikke).
- ▶ Vi forkaster nullhypotesen når  $p$ -verdien er *mindre* enn det valgte signifikansnivået, f.eks.  $\alpha = 0.05$  eller  $\alpha = 0.01$ .
- ▶ Dette vil garantere oss at *sannsynligheten* for å begå en Type I-feil (justismord) er mindre eller lik  $\alpha$ .

## Reporting results from hypothesis test

- ▶ Report  $p$ -value rather than e.g.  $t$ -statistic, since the  $p$ -value a “normalized” test statistic.
- ▶ Report confidence interval because that takes into account the precision of the estimated effect size.
- ▶ According to the *ISO Guide to the Expression of Uncertainty in Measurement (GUM)* the standard error should also be reported. For the  $t$ -test example this is  $\frac{s}{\sqrt{n}}$ .
- ▶ Statistical significance does not imply medical relevance.

## Ett utvalg: ensidig test for $\mu$ med $\sigma$ kjent [10.4]

► Ensidig test (større):

0.  $X_1, X_2, \dots, X_n$  u.i.f.  $N(\mu, \sigma^2)$  der  $\sigma$  er kjent.
1. En-sidig test (større):  $H_0 : \mu = \mu_0$  vs.  $H_1 : \mu > \mu_0$
2. Signifikansnivå  $\alpha$  bestemmes.
3. Testobservator  $Z_0 = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}}$  er under  $H_0$  standard normalfordelt.  
Forkast  $H_0$  hvis  $Z_0 > z_\alpha$ .
4. Observerer  $\bar{x}$  fra utvalget, beregn  $z_0 = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}}$ .  
Sammenlign  $z_0$  og  $z_\alpha$ , og forkast  $H_0$  hvis  $z_0 > z_\alpha$ .

► En-sidig test (mindre):

1.  $H_0 : \mu = \mu_0$  vs.  $H_1 : \mu < \mu_0$
3. Forkast  $H_0$  hvis  $z < z_\alpha$ .



## Ett utvalg: ensidig test for $\mu$ med $\sigma$ ukjent [10.4]

► Ensidig test (større):

0.  $X_1, X_2, \dots, X_n$  u.i.f.  $N(\mu, \sigma^2)$  der  $\sigma$  er ukjent.

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2.$$

1. En-sidig test (større),  $H_0 : \mu = \mu_0$  vs.  $H_1 : \mu > \mu_0$

2. Signifikansnivå  $\alpha$  bestemmes.

3. Testobservator  $T_0 = \frac{\bar{X} - \mu_0}{s/\sqrt{n}}$  er under  $H_0$  t-fordelt med  $n - 1$  frihetsgrader.

Forkast  $H_0$  hvis  $T_0 > t_{\alpha, (n-1)}$ .

4. Beregn  $\bar{x}$  og  $s$  fra utvalget, og videre  $t_0 = \frac{\bar{x} - \mu_0}{s/\sqrt{n}}$ .

Sammenlign  $t_0$  og  $t_{\alpha, (n-1)}$ , og forkast  $H_0$  hvis  $t > t_{\alpha, (n-1)}$ .

► En-sidig test (mindre):

1.  $H_0 : \mu = \mu_0$  vs.  $H_1 : \mu < \mu_0$

3. Forkast  $H_0$  hvis  $t_0 < t_{\alpha, (n-1)}$ .

## Ett utvalg: tosidig test for $\mu$ med $\sigma$ ukjent [10.4]

- $X_1, X_2, \dots, X_n$  u.i.f.  $N(\mu, \sigma^2)$  der  $\sigma$  er ukjent.  
$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2.$$
- To-sidig test:  $H_0 : \mu = \mu_0$  vs.  $H_1 : \mu \neq \mu_0$
- Signifikansnivå  $\alpha$  bestemmes.
- Testobservator  $T_0 = \frac{\bar{X} - \mu_0}{s/\sqrt{n}}$  er under  $H_0$  t-fordelt med  $n - 1$  frihetsgrader.  
Forkast  $H_0$  hvis  $|T_0| > t_{\frac{\alpha}{2}, (n-1)}$ .
- Beregn  $\bar{x}$  og  $s$  fra utvalget, og videre  $t_0 = \frac{\bar{x} - \mu_0}{s/\sqrt{n}}$ .  
Sammenlign  $t_0$  og  $t_{\frac{\alpha}{2}, (n-1)}$ , og forkast  $H_0$  hvis  $|t_0| > t_{\frac{\alpha}{2}, (n-1)}$ .

## To utvalg: statistisk situasjon

- ▶ Ønsker å sammenligne to populasjoner basert på et u.i.f. utvalg fra hver populasjon.
- ▶ Nå: Studerer en egenskap som kan sies å være normalfordelt i hver populasjon,
- ▶ og ønsker å utføre en hypotesetest om forholdet mellom forveningsverdiene i de to populasjonene
- ▶ Sammenligningene kan være parvise eller ikke parvise.
- ▶ Vi ser på binomisk situasjon i 10.9.

## 10.5: To utvalg, normalfordeling

### Situasjon: to uavhengige utvalg

- ▶  $X_{11}, X_{12}, \dots, X_{1n_1}$  er u.i.f.,  $X_{1i} \sim N(\mu_1, \sigma_1^2)$ .
- ▶  $X_{21}, X_{22}, \dots, X_{2n_2}$  er u.i.f.,  $X_{2j} \sim N(\mu_2, \sigma_2^2)$ .

**Problemstilling:** Vil teste hypotesen

$$H_0 : \mu_1 - \mu_2 = d_0 \quad \text{mot} \quad H_1 : \mu_1 - \mu_2 \neq d_0$$

(Alternativt:  $H_1 : \mu_1 - \mu_2 < d_0$  eller  $H_1 : \mu_1 - \mu_2 > d_0$ )

**Hypotesetest**, varianser kjente eller ukjente?

1.  $\sigma_1^2$  og  $\sigma_2^2$  kjente - vi jobber med normalfordelt testobservasjon.
2.  $\sigma_1^2$  og  $\sigma_2^2$  ukjente - vi jobber med t-fordelt testobservasjon.

## To uavhengige utvalg, normalfordeling (forts.)

1.  $\sigma_1^2$  og  $\sigma_2^2$  kjente: Bruker at

$$Z_0 = \frac{(\bar{X}_1 - \bar{X}_2) - d_0}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \sim N(0, 1) \quad \text{under } H_0.$$

Forkast  $H_0$  dersom  $|z_0| > z_{\frac{\alpha}{2}}$ , der  $z_0$  er observert verdi for  $Z_0$ .

2.  $\sigma_1^2 \neq \sigma_2^2$ ,  $\sigma_1^2$  og  $\sigma_2^2$  ukjente: Tilnærmet  $t$ -fordelt med "stygg"  $\nu$ . Se læreboka.

$$T_0 = \frac{(\bar{X}_1 - \bar{X}_2) - d_0}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \approx t_\nu \quad \text{under } H_0.$$

Forkast  $H_0$  dersom  $|t_0| > t_{\nu, \frac{\alpha}{2}}$ , der  $t_0$  er observert verdi for  $T_0$ .

## Læringsmål: husk å alltid tegne figur!

- ▶ Det er en klar sammenheng mellom en tosidig test (på nivå  $\alpha$ ) og et  $(1 - \alpha)100\%$  konfidensintervall.
- ▶ Forkastningsmetoden: finner forkastningsgrenser basert på en testobservator før man har observert data. Valgt signifikansnivå avgjør hvor strengt vi setter grensene.
- ▶ P-verdi-metoden: basert på data beregnes en p-verdi som angir sannsynligheten for det man har observer eller noe mer ekstremt (i hht  $H_1$ ) nå nullhypotesen er sann. Hvis  $p$ -verdien er mindre enn signifikansnivået forkaster vi nullhypotesen og sier at vi har funnet en signifikant sammenheng.
- ▶ En tosidig test bruker  $\alpha/2$  for forkastningsgrenser, og  $p$ -verdien å ta med nedre og øvre hale.
- ▶ En ensidig test bruker  $\alpha$  i forkastningsgrenser og  $p$ -verdien er basert på en hale. Hvis  $H_1 : \mu > 0$  skriver vi  $H_0 : \mu = 0$  selv om vi kan mene  $H_0 : \mu \leq 0$  fordi 0 er det mest ekstreme tilfellet.
- ▶ To-utvalgs t-test er kanskje den mest brukte test-situasjonen.