

## 6.2 Signifikanstester

- Konfidensintervaller er nyttige når vi ønsker å estimere en populasjonsparameter
- Signifikanstester er nyttige dersom vi ønsker å teste en hypotese om en parameter i en populasjon
- Bruker observerte data til å teste hypotesen om populasjonen
- Typisk prosedyre
  - Beregn sannsynlighet for observert utfall av en statistikk (eller noe mer ekstremt) gitt antatt hypotese
  - Hvis sannsynlighet liten, forkast hypotese

# Eksempel studielån

- Gjennomsnittlig studielån:


$\bar{x}_1 = \$21200$  ved private college

$\bar{x}_2 = \$17100$  ved offentlige college

– Forskjell \$4100 mellom private og offentlige college, reell eller tilfeldig?

–  $P(\text{Forskjell mellom } \bar{x}_1 \text{ og } \bar{x}_2 \geq 4100, \text{ gitt at det ikke er noen forskjell mellom forventningene i populasjonen}) = 0.17$

– Ganske høy sannsynlighet, altså ikke så veldig overraskende resultat, data gir ikke grunnlag for å påstå at det er forskjeller i lånenivå mellom private og offentlige college



**Difference in debt dollars**


**Figure 6-7**

*Introduction to the Practice of Statistics, Fifth Edition*

© 2005 W. H. Freeman and Company

# Eksempel studielån

- Gjennomsnittlig studielån
  - i 1997 er  $\bar{x}_1 = \$11400$
  - i 2002 er  $\bar{x}_2 = \$18900$
  - Forskjell \$7500 mellom 2002 og 1997
  - $P(\text{Forskjell mellom } \bar{x}_1 \text{ og } \bar{x}_2 \geq 7500, \text{ gitt at det ikke er noen forskjell mellom forventningene i populasjonen}) = 0.00004$
  - Data gir grunnlag for å forkaste hypotese om at det ikke er forskjeller i lånenivå mellom 2002 og 1997



**Figure 6-8**  
*Introduction to the Practice of Statistics, Fifth Edition*  
© 2005 W. H. Freeman and Company

# Hovedtrinn

Spørsmål: Forskjell mellom nivåer (forventninger)

Ser om data er *kompatibel med hypotesen om at det ikke er noen forskjell*

Hvis ikke overraskende forskjell (eks. sanns. 0.17)

–Ikke grunnlag i data for å påstå at det er en forskjell

Hvis overraskende stor forskjell (eks. sanns. 0.00004)

–Forkast antagelse om ingen forskjell

# Hypoteser

*Null-hypotese*  $H_0$

- Påstand som ønskes testet
- Typisk: Ingen effekt, Ingen forskjell mellom de ukjente forventningene
- Eks.  $H_0: \mu = \mu_1 - \mu_2 = 0$ , eventuelt  $\mu_1 = \mu_2$

*Signifikanstest*: Designet for å angi bevisstyrke *mot*  $H_0$

*Alternativ hypotese*  $H_a$

- Det er en effekt / forskjell
- Eks.  $H_a: \mu \neq 0$  eventuelt  $\mu_1 \neq \mu_2$

NB: Hypoteser er alltid utsagn/antagelser om populasjoner (eller modeller), ikke et spesielt utfall. Derfor må  $H_0$  og  $H_a$  alltid formuleres utifra de ukjente populasjonsparametrene, aldri statistikk(er)!!!

# Hypoteser

- Fordi  $H_a$  uttrykker effekten vi ønsker å finne ut om er tilstede, er det lurt å *starte med å formulere*  $H_a$  og deretter sette opp  $H_0$  som utsagnet om at den ønskede effekten ikke er tilstede
- Å formulere  $H_a$  er ofte den vanskeligste oppgaven. Spesielt er det ofte ikke opplagt om denne skal være *ensidig* (f.eks.  $H_a: \mu > 0$ ) eller *tosidig* (f.eks.  $H_a: \mu \neq 0$ )
  - uttrykker om parameteren er forskjellig fra nullhypoteseverdien i en bestemt retning eller ikke
  - Man får ikke lov til å se på data for å formulere  $H_a$  (juks!)
  - Dersom man ikke har god begrunnelse på forhånd om retning på effekten, skal man velge tosidig  $H_a$



# Teststatistikk

Baserer test på en statistikk som estimerer parameteren vi er interessert i (ofte den samme som vi ville brukt til et konfidensintervall for parameteren)

– Eks.:  $\bar{x}_1 - \bar{x}_2$  estimerer  $\mu = \mu_1 - \mu_2$

• Verdier langt fra parameterverdi spesifisert av  $H_0$  gir bevis mot  $H_0$

•  $H_a$  angir hvilken retning som teller:

– Ensidig  $H_a: \mu_1 > \mu_2$  angir at vi må ha stor  $\bar{x}_1 - \bar{x}_2$  som bevis mot  $H_0$

– Ensidig  $H_a: \mu_1 < \mu_2$  angir at vi må ha liten  $\bar{x}_1 - \bar{x}_2$  som bevis mot  $H_0$

– Tosidig  $H_a: \mu_1 \neq \mu_2$  angir at vi må ha stor  $|\bar{x}_1 - \bar{x}_2|$  som bevis mot  $H_0$

# Standardisert test-statistikk

For å undersøke hvor langt estimatet er fra parameterverdien spesifisert av  $H_0$ , standardiserer vi estimatet

$$z = \frac{\textit{estimat} - \textit{parameterverdi under } H_0}{\textit{standard avvik for estimat}}$$

# Eksempel studielån

Forskjell på de ukjente, sanne forventningene til størrelse på lån ved private og offentlige college?

$H_0$ : Det er ingen forskjell i de sanne forventningene

$H_a$ : Det er en forskjell i de sanne forventningene

Dvs:  $H_0: \mu_1 = \mu_2$  mot  $H_a: \mu_1 \neq \mu_2$  (tosidig alternativ)

Vi får oppgitt:  $\sigma_{\bar{x}_1 - \bar{x}_2} = 3000$

# Signifikanstest: P-verdi

- *P-verdi*: Sannsynligheten for at et utfall er like ekstremt eller mer ekstremt enn faktisk utfall (beregnet ved å anta at parameterverdien gitt av  $H_0$  er sann)
  - Ekstremt: Lang fra hva vi ville forvente hvis  $H_0$  var sann. Retning på hva som regnes som ekstremt: Bestemmes av  $H_a$  og  $H_0$
  - *Jo mindre P-verdien er, jo sterkere bevis har vi mot  $H_0$*

# Eksempel studielån

Forskjell mellom private og offentlige college?

$H_0: \mu_1 - \mu_2 = 0$  mot  $H_a: \mu_1 - \mu_2 \neq 0$

Estimat for  $\mu_1 - \mu_2$ :  $\bar{x}_1 - \bar{x}_2$  (= 4100)

Ekstremt: Langt fra hva vi ville forvente hvis  $H_0$  var sann, dvs store verdier av både positive og negative forskjeller, dvs store verdier av absoluttverdien  $|\bar{x}_1 - \bar{x}_2|$  teller som bevis mot  $H_0$

Utfall er like ekstremt eller mer ekstremt enn faktisk utfall: Like store eller større enn observert verdi av absoluttverdien  $|\bar{x}_1 - \bar{x}_2|$ , som betyr like store eller større enn observert verdi av  $|z|$ , der  $z$  er standardiserert test-statistikk (gitt  $H_0: \mu_1 - \mu_2 = 0$ ):  $z = (4100 - 0) / 3000 = 1.37$

# Eksempel studielån

*P-verdi*: Sannsynligheten for at et utfall er like ekstremt eller mer ekstremt enn faktisk utfall (beregnet ved å anta at parameterverdien gitt av  $H_0$  er sann)

Standardiserert, observert test-statistikk (gitt  $H_0: \mu_1 - \mu_2 = 0$ ):

$$z = (4100 - 0) / 3000 = 1.37$$

Utfall er like ekstremt eller mer ekstremt enn faktisk utfall: Like store eller større enn observert verdi av absoluttverdien  $|\bar{x}_1 - \bar{x}_2|$ , som betyr like store eller større enn observert verdi av  $|z|$

Z tilnærmet  $N(0,1)$ : *P-verdi* =




Figure 6-9  
*Introduction to the Practice of Statistics, Fifth Edition*  
© 2005 W. H. Freeman and Company

# Statistisk signifikans

Hvordan konkludere?

- Forkaster  $H_0$  når *P-verdi* er liten nok

*Signifikansnivå*  $\alpha$ : Grenseverdi for når vi forkaster

–Forkaster  $H_0$  når *P-verdi*  $\leq \alpha$

–Ikke grunnlag for å forkaste  $H_0$  når *P-verdi*  $> \alpha$

–Typisk:  $\alpha=0.05$  (eller 0.01)

*Signifikant* betyr at bevisene mot nullhypotesen oppfyller standarden satt av  $\alpha$ . Typisk utsagn er «Resultatene er signifikante ( $P < 0.05$ )»

- Hvis vi velger signifikansnivå  $\alpha=0.05$  krever vi at dataene gir bevis mot  $H_0$  som bare vil skje i 5% av tilfellene hvis  $H_0$  er sann
- Hvis vi velger signifikansnivå  $\alpha=0.01$  krever vi at dataene gir bevis mot  $H_0$  som bare vil skje i 1% av tilfellene hvis  $H_0$  er sann
  - Vi krever altså sterkere bevis mot  $H_0$  hvis vi velger  $\alpha=0.01$  enn hvis vi velger  $\alpha=0.05$



# Signifikanstest

1. Formuler  $H_0$  og  $H_a$
2. Beregn test-statistikk
3. Finn P-verdi
4. Formuler en konklusjon

NB: Bruker ofte datamaskin til å finne P-verdi, men en datamaskin

- **Kan ikke** formulere  $H_0$  og  $H_a$
- **Kan ikke** tolke P-verdien for deg
- **Kan ikke** bedømme om forutsetningene for å bruke testen er oppfylt

# Eksempel studielån

Forskjell mellom private og offentlige college?

$H_0: \mu_1 - \mu_2 = 0$  mot  $H_a: \mu_1 - \mu_2 \neq 0$

Estimat for  $\mu_1 - \mu_2$ :  $\bar{x}_1 - \bar{x}_2$  (= 4100)

Standardiserer:  $z = (4100 - 0) / 3000 = 1.37$

Z tilnærmet  $N(0,1)$ :

$$\begin{aligned} - P\text{-verdi} &= P(|Z| > 1.37) = P(Z < -1.37) + P(Z > 1.37) \\ &= 2 * P(Z < -1.37) = 2 * 0.0853 = 0.1706 \end{aligned}$$

Eksempel på tolkning og konklusjon:

Det er 17% sjanse for å observere en forskjell like ekstrem eller mer ekstrem som den observerte forskjellen på \$4100 hvis den sanne populasjons-forskjellen mellom forventningene er 0. P-verdien sier oss altså at det observerte utfallet ikke er spesielt ekstremt. Vi kan si at de observerte dataene ikke gir grunnlag for å konkludere at det er en signifikant forskjell i forventet studielån mellom private og offentlige skoler

# Eksempel studielån

Økning i størrelsen på studielån fra 1997 til 2002?

$H_0: \mu_2 - \mu_1 = 0$  mot ensidig  $H_a: \mu_2 - \mu_1 > 0$ ,

Estimat for  $\mu_2 - \mu_1$ :  $\bar{x}_2 - \bar{x}_1$  (= 7500)

Vi får oppgitt:  $\sigma_{\bar{x}_1 - \bar{x}_2} = 1900$

Standardiserer (parameterverdi under  $H_0$  er  $\mu_2 - \mu_1 = 0$ ):

$$z = (7500 - 0) / 1900 = 3.95$$

Z tilnærmet  $N(0,1)$ :

$$- P\text{-verdi} = P(Z > 3.95) = 0.00004$$

*Eksempel på tolkning og konklusjon:* Det er en 4 til 100.000 sjanse for å observere en forskjell like stor eller større som den observerte forskjellen på \$7500 hvis den sanne populasjons-forskjellen mellom forventningene er 0. *P-verdien sier oss altså at det observerte utfallet er ekstremt sjeldent. Vi konkluderer at de observerte dataene gir grunnlag for å konkludere at nullhypotesen er feil.* Dataene viser tydelig at forventet studielån har økt mellom 1997 og 2002 ( $P < 0.001$ )

# Tester for populasjonsforventning

$$H_0: \mu = \mu_0$$

$$\text{Data: } x_1, \dots, x_n$$

$$\text{Estimator for } \mu: \bar{x}$$

$$\text{Teststatistikk: } z = (\bar{x} - \mu_0) / \sigma_{\bar{x}} = (\bar{x} - \mu_0) / (\sigma / \sqrt{n})$$


## Z TEST FOR A POPULATION MEAN

To test the hypothesis  $H_0: \mu = \mu_0$  based on an SRS of size  $n$  from a population with unknown mean  $\mu$  and known standard deviation  $\sigma$ , compute the test statistic


$$z = \frac{\bar{x} - \mu_0}{\sigma / \sqrt{n}}$$

In terms of a standard normal random variable  $Z$ , the  $P$ -value for a test of  $H_0$  against


$$H_a: \mu > \mu_0 \text{ is } P(Z \geq z)$$



$$H_a: \mu < \mu_0 \text{ is } P(Z \leq z)$$



$$H_a: \mu \neq \mu_0 \text{ is } 2P(Z \geq |z|)$$



These  $P$ -values are exact if the population distribution is normal and are approximately correct for large  $n$  in other cases.

# Eksempel: Blodtrykk

Blodtrykk menn alder 35-44 har forventning 128 og standardavvik  $\sigma=15$

En bedriftslege ønsker å undersøke: Har mannlige toppledere (alder 35-44) i bedriften annerledes forventet blodtrykk enn den generelle populasjonen av menn på samme alder (som er 128)?

Målinger av blodtrykket til 72 toppledere:  $\bar{x} = 126.07$


Bedriftslegen har ingen grunn til å anta noen retning på forskjellen. Vi kan anta at standardavviket for mannlige toppledere også er  $\sigma=15$ .

–  $H_0: \mu = \mu_0 = 128$ ,  $H_a: \mu \neq \mu_0$  der  $\mu_0 = 128$

–  $z = (126.07 - 128) / (15 / \sqrt{72}) = -1.09$

– P-verdi =

**$P = 0.2758$**



**Figure 6-11**  
*Introduction to the Practice of Statistics, Fifth Edition*  
© 2005 W.H. Freeman and Company

## Eksempel: Blodtrykk

- P-verdi = 0.2758
- Tolkning og konklusjon: Et SRS med  $n=27$  fra den generelle populasjonen av menn på samme alder vil 27% av gangene gi et gjennomsnittlig blodtrykk like langt eller lenger fra 128 som det observerte  $\bar{x}=126.07$ . Den observerte  $\bar{x}$  gir altså ikke bevis for at topplederene er annerledes enn andre menn på samme alder. Ingen grunn til å forkaste  $H_0$



# To-sidige tester og konfidensintervall

Konfidensintervall med konfidens C:

$$[\bar{x} - z^* \sigma / \sqrt{n}, \bar{x} + z^* \sigma / \sqrt{n}]$$

Dette er laget fra de observerte dataene for ett utvalg. Verdier av  $\mu$  utenfor intervall er ikke compatible med de observerte data.

Mulig test-prosedyre:

- Forkaste  $H_0: \mu = \mu_0$  hvis  $\mu_0$  ikke er i konfidensintervallet

Kan vises: Ekvivalent med signifikanstest

*En tosidig signifikanstest med nivå  $\alpha$  som forkaster  $H_0: \mu = \mu_0$  er ekvivalent med at  $\mu_0$  faller utenfor konfidensintervallet for  $\mu$  med nivå  $C = 1 - \alpha$*

Noen ganger enklere å konstruere konfidensintervaller

# Eksempel: To-sidige tester og konfidensintervall


- Analyse av konsentrasjonen av farmasøytisk produkt. Ikke presis målemetode, repeterte analyser av samme prøve vil gi litt forskjellig svar. Vi vet at konsentrasjon  $N(\mu, \sigma=0.0068)$ -fordelt
- Laboratoriet har blitt spurt om å evaluere en påstand om at konsentrasjonen i en prøve er 0.86%
  - $H_0: \mu=0.86$      $H_a: \mu \neq 0.86$
  - Tre målinger av prøven ga resultatene 0.8403, 0.8363 og 0.8447
  - $\bar{x}=0.8404$ , ,  $\sigma=0.0068$ ,  $n=3$

# Eksempel: To-sidige tester og konfidensintervall

- I stedet for å gjøre signifikanstesten, kan vi alternativt lage et konfidensintervall og se om  $\mu_0=0.86$  er innenfor eller utenfor dette intervallet. For signifikansnivå 0.01 må vi lage et 99% konfidensintervall (fordi  $1-0.01=0.99$ )
- $\bar{x} = 0.8404$ ,  $\sigma = 0.0068$ ,  $n=3$

**Cannot reject  $H_0$ ;  $\mu = 0.85$**

**Reject  $H_0$ ;  $\mu = 0.86$**



**Figure 6-13**

*Introduction to the Practice of Statistics, Fifth Edition*

© 2005 W. H. Freeman and Company

# P-verdier mot fast nivå $\alpha$

To mulige måter å rapportere:

- Hvis P-verdi  $< \alpha$ , så at  $H_0$  er forkastet på nivå  $\alpha$
- Angi P-verdi direkte

Testing farmasøytisk produkt: Konsentrasjon  $N(\mu, \sigma=0.0068)$

•  $H_0: \mu=0.86$      $H_a: \mu \neq 0.86$

• Observasjoner 0.8403, 0.8363, 0.8447


•  $\bar{x}=0.8404$

•  $z=(0.8404-0.86)/(0.0068/\sqrt{3})=-4.99$

•  $P=2P(Z>|-4.99|)<0.0004$

– Signifikant på 0.05 nivå, 0.01 nivå, og 0.001 nivå. Faktisk signifikant helt ned til 0.0004-nivå

***Generelt: P-verdi er det laveste signifikansnivå som gir forkastning.***



**Figure 6-14**  
*Introduction to the Practice of Statistics, Fifth Edition*  
© 2005 W. H. Freeman and Company

## 6.3 Bruk og misbruk av tester

Utføre test er enkelt (software), å bruke test vanskeligere

- Kun gyldig under visse forutsetninger
- Konfidensnivå: Ingen klar grense, vanlig å rapportere P-verdi
- Forkastning  $H_0$ : Effekt statistisk signifikant
- Men effekten kan være liten! (hvis  $n$  er stor)
- Ingen forkastning behøver ikke bety  $H_0$  er sann
- Ofte mulig å gjøre mange mulige tester
  - P-verdi relatert til å gjøre *en* test
  - Hvis man gjør mange tester må justeringer gjøres



# Eksempel liten effekt som er signifikant: Testing av en korrelasjon

- To variable
  - $H_0$ : Ingen korrelasjon mellom de to variablene ( $\rho = 0$ )
  - $H_a$ : Det er korrelasjon mellom de to variablene ( $\rho \neq 0$ )
- 400 observasjoner, observerer  $r=0.1$
- Signifikanstest viser at det er en statistisk signifikant korrelasjon mellom de to variablene på signifikansnivå  $\alpha=0.05$
- Observert variasjon i den ene variabelen forklart av den andre variabelen:  $r^2=0.1^2=0.01$
- At testen viser at det er en statistisk signifikant korrelasjon betyr altså ikke at det er en sterk sammenheng mellom variablene, bare at det er sterke bevis for at det er noe sammenheng

# Hiv-behandling

- Behandlingsgruppe og kontrollgruppe
- Insidensrateforhold I:
  - Forhold mellom smitterate i behandlingsgruppe i forhold til kontrollgruppe
  - H0:  $I=1$  (lik smitterate smitterate i behandlingsgruppe og kontrollgruppe)
  - 95% konfidensintervall: [0.63,1.58]
  - Kan ikke forkaste nullhypotesen om at smitterate er lik i behandlingsgruppe og kontrollgruppe, men det betyr ikke at nullhypotesen er sann!
  - Konfidensintervallet indikerer at behandling både kan gi forbedringer og forverringer!
  - Mer data er nødvendig for å finne ut hva som er riktig

# Genomiske eksperimenter

- Ønsker å finne gen som forklarer sykdom
- Mange titusener mulige gener
- Kan utføre en test på hvert gen
  - 10 000 tester,  $\alpha=0.05$ , dvs ca 5% av 10 000 tester vil være signifikante bare pga tilfeldigheter
  - Dvs forventer at 500 tester vil være signifikante kun pga. tilfeldigheter!
- Forskning:
  - Hvordan behandle mange tester simultant