

Kap 10, Totvalgsdata, fort.s.  
 $X_1, \dots, X_n \sim f(x; \theta_1)$  uent  $E \theta_1 = \theta_2$   
 $Y_1, \dots, Y_n \sim f(x; \theta_2)$   
 Spesielt internt forvent  $\mu_1 = E(X_i)$  og  $\mu_2 = E(Y_i)$   
 Betrakten  $Z = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} \sim N(0,1)$  Ekkelt u. normf. dat.  
 Må anta  $U_n(\bar{X} - \bar{Y}) = \frac{\sigma_1^2 + \sigma_2^2}{n} + \frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}$  når  $\sigma_1^2 = U_n(X_i) \neq \sigma_2^2 = U_n(Y_i)$   
 da  $\sigma_0^2 = \frac{(n-1)\sigma_1^2 + (n-1)\sigma_2^2}{n+n-2}$  når  $\sigma_1^2 = \sigma_2^2 = \sigma^2$   
 Da er  $t = \frac{(\bar{X} - \bar{Y}) - \Delta}{\sqrt{\frac{\sigma^2}{n} + \frac{\sigma^2}{n}}} \sim t_{2n-2}$  når  $\sigma_1^2 = \sigma_2^2$   
 Teste på disse balgjen  $H_0: \mu_1 = \mu_2$  og konsejn  
 KI for  $\mu_1 - \mu_2$

okt 3-12:14

Stykebeholdningen  
 Med kjente  $\sigma_1$  og  $\sigma_2$  bli stykefunksjon  $f_n$   
 $H_0: \mu_1 = \mu_2$  ut  $H_1: \mu_1 > \mu_2$  med nivå  $\alpha$ ,  $\Delta = \mu_1 - \mu_2$   
 $\gamma(\delta) = P\left(\frac{\bar{X} - \bar{Y}}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} > z_{\alpha} \mid \mu_1 - \mu_2 = \Delta\right)$   
 $= P(\text{Faktor } H_0 \mid \mu_1 - \mu_2 = \Delta)$   
 $= P\left(\frac{\bar{X} - \bar{Y} - \Delta}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} > z_{\alpha} - \frac{\Delta}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}}\right)$   
 $= \Phi\left(\frac{\Delta}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{n}}} - z_{\alpha}\right)$   
 Med fikant  $\Delta$   $n \rightarrow \infty$ ,  $n \rightarrow \infty$  så vi ( $U_n(\bar{X} - \bar{Y}) \rightarrow 0$ )  
 $\gamma(\delta) \rightarrow 1$  når  $\Delta > 0$   
 Med  $\sigma_1$  og  $\sigma_2$  kreva et numerisk integral for å finne  
 stykefunksjon.  
 Bruk softvare: power.t.test ; R

okt 3-12:25

Hva innebærer det at  $\theta_1 \neq \theta_2$ .  
 Eks) Utv 1 Temp 2001-2016  
 Utv 2 Temp 1961-1990  
 Eks) Utv 1 Regkone  
 Utv 2 Ikke regkone  
 Er forskjellene gitt av årsaker, kausale  
 alle bare assosiasjoner - faktorer på som vi ikke  
 kan kjenne til årsaker  
 Observasjonelle studier - må passivt observere data  
 Planlagt eksperiment - kan aktivt velge verdi av faktor  
 for hver studie og kontroll  
 Særlig for observasjonelle studier er det stor risiko  
 for at sammenheng er spuriøs,  
 skyldes konfunderte eller sammenblandede effekter.  
 • (ukjente (lurking) variabler

okt 3-12:33

Ex) Lungekraft og røyking  
 Ex) Livsmønstre knytt til HPV, røyking, alkohol  
 Ex) Fedtetsvekt og mors utdanning, røyking  
 Ex) Størrelse og fedtstall  
 For at vi skal ha representerer sammenheng må  
 vår variabel være knyttet/korrelert med de vi vil undersøke.  
 Hvis de konfunderte variablene er observert, så kan vi  
 "justere" for dem i multiple regresjonsanalyse (Kap. 12)  
 For et planlagt eksperiment derimot kan man  
 randomisere  
 dvs. trekke tilfeldig hvem som får ulike behandlinger.  
 Dermed oppheves uavhengighet mellom behandling og  
 ukjente variabler  $\theta_1 \neq \theta_2$  signifikant  
 kan forskjellen tilskrives årsak.

okt 3-12:45

Parede data, 10.3  
 $X_i =$  svangers med bek 1 Begge fra studie A/B  
 $Y_i =$  " " " 2  $i = 1, \dots, n$   
 Særlig  $(X_i, Y_i)$  være avhengige  
 Er  $\mu_0 = \mu_1 - \mu_2 = E(Y_i) - E(X_i)$   
 (ik alle ulike null.  
 Ex)  $X_i =$  ant myssstikk ann 1 med myssmiddel A B  
 $Y_i =$  " " " 2  
 Ber randomisere om begge lavste hånd for A/B  
 Ex)  $X_i =$  temperaturproblema barn A an man i miljøet  
 $Y_i =$  " " " B  
 Ber A og B oppkone, men kan ikke randomisere  
 A/B er naturlige å studere  $D_i = X_i - Y_i$   
 f. ex med antuglse  $D_i \sim N(\mu_0, \sigma_0^2)$   
 Selvom dette er samlingning av to faktorer kan  
 vi ved kjent i transformere til tittelvalgsdata  
 $D_1, D_2, \dots, D_n$   
 Iufors følge direkte fra metodene i Kap 7-9.

okt 3-13:13

Vi anta  $\mu_0$  med  $\hat{\mu}_0 = \bar{D} = \bar{X} - \bar{Y}$   
 og  $\sigma_0^2 = \frac{1}{n-1} \sum (D_i - \bar{D})^2$   
 Videre får vi at  $(1-\alpha)100\%$  KI for  $\mu_0$  ved  
 $\bar{D} \pm t_{\alpha/2} \frac{\hat{\sigma}_0}{\sqrt{n}}$  ( $t_{\alpha/2}$  fra  $t_{n-1}$  ford.)  
 og teste  $H_0: \mu_0 = 0$  ut  $H_1: \mu_0 \neq 0$   
 ved  $t = \frac{\bar{D}}{\hat{\sigma}_0/\sqrt{n}} \sim t_{n-1}$  under  $H_0$ .  
 Betrakt to studie opplegg (design)  
 1. n personer i utv. 1 - myssmiddel A  
 n " " " 2 " " " B  
 Analyse med vanlig totvalgs metode l. l.  
 2. Paard studie. For same individ f. e.  
 Ann 1 middel A  $X_i = u$   
 Ann 2 middel B  $Y_i = u$   
 Vi antar godt design at  $U_n(X_i) = U_n(Y_i) = \sigma^2$   
 Ved oppsett i blir  $U_n(\bar{X} - \bar{Y}) = \frac{\sigma^2}{n} + \frac{\sigma^2}{n} = \frac{2\sigma^2}{n}$   
 Ved oppsett 2 blir  $U_n(X_i - Y_i) = U_n(X_i) + U_n(Y_i) - 2Cov(X_i, Y_i)$   
 $= \sigma^2 + \sigma^2 - 2\rho\sigma^2 = 2\sigma^2(1-\rho)$   
 Det blir  $U_n(\bar{X} - \bar{Y}) = \frac{2\sigma^2}{n}(1-\rho) < \frac{2\sigma^2}{n}$  hvis  $\rho > 0$   
 Dermed er parede studier mer informative enn vanlig to-  
 utvalg med positiv  $\rho$ .  
 Hvis  $\rho = 0$  taper vi faktisk greide, for  $2n-2$  til  $n-1$

okt 3-13:30

To binomiske variabler, 10.4

Utv. 1  $n$  forsøk,  $X =$  antall suksesser  $\sim \text{Bin}(n, p_1)$

Utv. 2  $n$  " "  $Y =$  " "  $\sim \text{Bin}(n, p_2)$

Utv. analyse av uavhengige

Ønsker KI for  $p_1 - p_2$   $\Rightarrow$  test av  $H_0: p_1 = p_2$

Estimator  $\hat{p}_1 = \frac{X}{n}$   $\Rightarrow$   $\hat{p}_2 = \frac{Y}{n}$  for  $p_1$  og  $p_2$ .

Da  $\mu = E[\hat{p}_1 - \hat{p}_2] = p_1 - p_2$

$\Rightarrow$   $V_{\hat{p}_1 - \hat{p}_2} = V_{\hat{p}_1} + V_{\hat{p}_2} = \frac{p_1(1-p_1)}{n} + \frac{p_2(1-p_2)}{n}$

$p_1 = p_2 = p \rightarrow = p(1-p) \left(\frac{1}{n} + \frac{1}{n}\right)$

$\Rightarrow \hat{p}_1 - \hat{p}_2 \stackrel{\text{tiln}}{\sim} N\left(p_1 - p_2, \frac{p_1(1-p_1)}{n} + \frac{p_2(1-p_2)}{n}\right)$

Test for  $H_0: p_1 = p_2$  gir ved test obs.

$Z = \frac{\hat{p}_1 - \hat{p}_2}{\sqrt{V_{\hat{p}_1 - \hat{p}_2}}} = \frac{\hat{p}_1 - \hat{p}_2}{\sqrt{p(1-p)\left(\frac{1}{n} + \frac{1}{n}\right)}} \stackrel{\text{tiln}}{\sim} N(0, 1)$

$\Rightarrow \hat{p} = \frac{X+Y}{n+n}$  estimat for  $p = p_1 = p_2$  under  $H_0$ .

okt 3-13:43

Finlende feb.  $H_0$  mot alt.  $H_1: p_1 \neq p_2$ , hvor  $d$  er

$|Z| > z_{\alpha/2} = (1 - \frac{\alpha}{2})$  100 prosentil i  $N(0, 1)$ .

og et tiln 95% KI for  $p_1 - p_2$  gir ved

$\hat{p}_1 - \hat{p}_2 \pm 1.96 \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n} + \frac{\hat{p}_2(1-\hat{p}_2)}{n}}$

$\sim$  tiln  $p_1 \neq p_2$ , bør ha god varians estimator.

Software: binom.test i R

Mer et utskrift for denne kunne av. ha litt for formel over pga.

- Kontinuitetskorreksjon
- Kan tillate eksakte nettsider (Eksakt Fisher test)



okt 3-13:53