

**TENTAMEN:** Matematisk statistik för K (25 maj, 2005)

**Kortfattade lösningar:**

- 1) a)  $P(E \cap F) = P(F|E)P(E) = 0.20 \cdot 0.55 = 0.11$   
b)  $P(E \cup F) = P(E) + P(F) - P(E \cap F) = 0.55 + 0.40 - 0.11 = 0.84$   
c)  $P(E|F) = \frac{P(E \cap F)}{P(F)} = \frac{0.11}{0.40} = 0.275$
- 2) a) Ett 99% konfidensintervall är  $\bar{x} \pm t_{\alpha/2}s/\sqrt{n}$ , där  $\bar{x} = 2.89$ ,  $s = 3.92$ ,  $\alpha = 0.01$ ,  $n = 10$  och  $t_{0.005} = 3.25$  (antalet frihetsgrader är  $10 - 1 = 9$ ). Då blir konfidensintervallet  $2.89 \pm 3.25 \cdot 3.92/\sqrt{10} = 2.89 \pm 4.03$ , dvs.  $[-1.14, 6.92]$ .  
b) Enligt a) är den sanna medelnivån av bly i dricksvattnet mellan -1.14 och 6.92  $\mu\text{g/l}$ . Blynivån kan inte vara negativ så att man borde säga att medelnivån är lägre än 6.92  $\mu\text{g/l}$  men större än 0.  
c) 99% av stickproven av storlek 10 skulle ge ett konfidensintervall som täcker det sanna medelblynivån (man är 99% konfident att medelnivån av bly ligger på det beräknade intervallet). Bara en gång i 100 skulle man få ett intervall som inte innehåller det sanna värdet.  
d) Stickprovet kommer från en normalfördelning.
- 3) a) Vikten  $X \sim N(1.03, 0.014)$ . Då är  $P(X < 1) = P\left(\frac{X-1.03}{0.014} < \frac{1-1.03}{0.014}\right) = P(Z < -2.14) = 0.0162$ , där  $Z \sim N(0, 1)$ .  
b) Nu är vikten  $X \sim N(1.05, 0.016)$  och  $P(X < 1) = P\left(\frac{X-1.05}{0.016} < \frac{1-1.05}{0.016}\right) = P(Z < -3.13) = 0.0009$ . Detta betyder att andelen underviktiga paket minskar.
- 4) Låt  $X$  vara vithetsnivån med låg nivå och  $Y$  med hög nivå av väteperoxid. Väntevärdena och varianserna av  $X$  och  $Y$  är  $\mu_X$  resp.  $\mu_Y$  och  $\sigma_X^2$  resp.  $\sigma_Y^2$   
a) För att testa hypotesen  $H_0 : \mu_X = \mu_Y$  mot  $H_1 : \mu_X \neq \mu_Y$  kan man använda två stickprovs  $T$ -testet ( $\sigma$  okänd). Teststatistikan är  $T = (\bar{X} - \bar{Y}) / (S \sqrt{\frac{1}{n_X} + \frac{1}{n_Y}}) \sim T_{n_X+n_Y-2}$ , där  $S^2 = ((n_X - 1)S_X^2 + (n_Y - 1)S_Y^2) / (n_X + n_Y - 2)$ . Nu är  $s^2 = 14.44$  och  $t = -1.50$ .  $\alpha = 0.05$  och därför jämförs värdet av teststatistikan med  $t_{0.025} = 2.035$  (eller  $-t_{0.025} = -2.035$ ). Antalet frihetsgrader är  $n_X + n_Y - 2 = 33$ . Värdet av teststatistikan är inte på kritiska området ( $-2.035 < -1.50 < 2.035$ ) och därför förkastar man inte  $H_0$ . Man kan inte säga att det finns någon skillnad mellan de olika vithetsnivåerna.  
b)  $X \sim N(\mu_X, \sigma)$  och  $Y \sim N(\mu_Y, \sigma)$ . Varianserna kan antas vara lika men  $Y$  verkar inte vara normalfördelad.

- 5) a) Man har två stokastiska variabler  $X$  och  $Y$  och man är intresserad av sambandet mellan dem.  $Y$  är stokastisk och  $X$  är mätt utan fel. Man plottar först grafen  $Y$  mot  $x$  och om sambandet ser linjärt ut, kan en linjär regressionsmodell vara en lämplig modell.
- b) Man antar att felet  $E_i \sim N(0, \sigma)$ . (Då är också  $Y$  normalfördelad). Då vet man att  $(\hat{\beta}_1 - \beta_1)/(S/\sqrt{\sum(x_i - \bar{x})^2}) \sim T_{n-2}$  och att  $P(-t_{0.05} \leq (\hat{\beta}_1 - \beta_1)/(S/\sqrt{\sum(x_i - \bar{x})^2}) \leq t_{0.05}) = 0.90$ , där  $P(T > t_{0.05}) = 0.05$ ,  $T \sim T_{n-2}$  och  $n$  är stickprovsstorleken. Genom att lösa olikheten ovan m.a.p.  $\beta_1$  får man att ett 90% konfidensintervall för  $\beta_1$  är  $\hat{\beta}_1 \pm t_{0.05}S/\sqrt{\sum(x_i - \bar{x})^2}$ , där  $\hat{\beta}_1 = (n \sum x_i Y_i - \sum x_i \sum Y_i)/(n \sum x_i^2 - (\sum x_i)^2)$   $S^2 = \sum(Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2/(n - 2)$  och  $\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x}$ .
- 6) De två stickproven är inte oberoende och därför utför man ett parvist test (som är samma som ett stickprovs  $T$ -test) för att testa  $H_0 : \mu_D = \mu_A - \mu_B = 0$  mot  $H_1 : \mu_D \neq 0$ . Man definierar  $D_i = A_i - B_i$  och får att  $\bar{d} = -2.906$  och  $s_d = 8.895$ . Teststatistikan (som är  $T_{31}$ -fördelad) är  $\bar{D}/(S_d/\sqrt{n})$  och dess värde är  $-2.906/(8.895/\sqrt{32}) = -1.848$ . Värdet jämförs med  $t_{0.025} = 2.040$  (och  $-t_{0.025} = -2.040$ ), antal frihetsgrader är  $n - 1 = 31$ . Teststatistikans värde är inte på kritiska området och vi kan inte förkasta  $H_0$ . Man kan inte säga att det finns någon skillnad mellan IQ-poängtal av tvillingspar beroende på vem har uppfostrat dem. (Antalet observationer är tillräckligt stort och vi kan anta att  $\bar{D}$  är approximativt normalfördelad.)
- 7) a) Man testar  $H_0 : \mu = 68$  mot  $H_1 : \mu > 68$ , där  $\mu$  är väntevärdet av medelhöjden som antas vara normalfördelad (med okänd varians). Ett stickprovs  $T$ -test: Teststatistikan  $T = (\bar{X} - \mu)/(S/\sqrt{n})$  är  $T_{19}$ -fördelad och får värdet 3.39. Värdet jämförs med  $t_{0.01} = 2.539$  från  $T_{19}$ -fördelningen. Man förkastar  $H_0$  på signifikansnivån 0.01 därför att teststatistikans värde 3.39 är större än 2.539. Man kan säga att datan stöder påståendet att medelhöjden är större än 68 tum.
- b) Man använder teckentestet och testar  $H_0 : M = 68$  mot  $H_1 : M > 68$ , där  $M$  är medianhöjden. Antalet positiva skillnader  $(X_i - 68)$ ,  $Q_+$  är 14. Vi har två nollor i datan och de har ändrats till minustecken. Då kan man räkna  $p$ -värdet  $P(Q_+ \geq 14 | Q_+ \sim Bin(20, 0.5))$  är  $(\frac{1}{2})^{20} \sum_{x=14}^{20} \binom{20}{x} = 0.058$ . Nu är  $p$ -värdet större än signifikansnivån 0.01 och därför kan man inte förkasta  $H_0$ , dvs. att datan stöder inte påståendet att medelhöjden är större än 68 tum.
- c) Höjden kan inte antas vara normalfördelad att därför ger testet baserat på normalfördelningsantagandet inte samma resultat som det icke-parametriska testet. Man borde lita på det ickeparametriska testet.