

TENTAMEN: Matematisk statistik för K (30 maj, 2007)

Kortfattade lösningar:

- 1) a) $P(A \cup B) = P(A) + P(B) - P(A \cap B) = P(A) + P(B) - P(A)P(B|A)$
och vi får att $P(A) = (P(A \cup B) - P(B))/(1 - P(B|A)) = \frac{2}{7}$.
- b) $P(A \cap B) = P(A)P(B|A) = \frac{2}{7} \cdot 0.3 = \frac{3}{35}$.
- c) $P(A \cap B) = \frac{3}{35} \neq 0$, dvs. att A och B inte är disjunkta händelser.
- d) $P(A \cap B) = \frac{3}{35} \neq 0.174 = \frac{2}{7} \cdot 0.6 = P(A)P(B)$ och därför är A och B inte oberoende.
- 2) a) $f(x) \geq 0$ och $\int_{-\infty}^{\infty} f(x) dx = 1$
- b) $f(x) = \frac{3}{8} + cx$, $0 \leq x \leq 3$, är en täthetsfunktion om $\int_0^3 f(x) dx = 1$,
dvs. om $c = -\frac{1}{36}$ (då är också $f(x) > 0$ på $[0, 3]$).
- 3) a) Låt μ_1 och μ_2 vara de sanna väntevärdena av korrosionshastigheten av gjutgärn med 0.1% resp. 0.2% krominnehåll. \bar{X}_1 och \bar{X}_2 , och S_1 och S_2 är de motsvarande medelvärdena och stickprovsstandardavvikelserna. Man vill testa hypotesen $H_0 : \mu_1 = \mu_2$ mot $H_1 : \mu_1 \neq \mu_2$ och använder två stickprovs dubbelsidigt T -test. Teststatistikan

$$T = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{S_p^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}}$$

där $S_p^2 = ((n_1 - 1)S_1^2 + (n_2 - 1)S_2^2)/(n_1 + n_2 - 2)$, är $T_{n_1+n_2-2}$ -fördelad om H_0 är sann. Nu är $s_p^2 = 0.0935$, $t = 1.356$ och $t_{0.005}^{(23)} = 2.807$. Nu är $-t_{0.005}^{(23)} = -2.807 < t = 1.356 < 2.807 = t_{0.005}^{(23)}$ och vi kan inte förkasta H_0 . Dvs. att man kan inte säga att krominnehållet påverkar korrosionshastigheten

- b) 99% konfidensintervall för $\mu_1 - \mu_2$ är $\bar{x}_1 - \bar{x}_2 \pm t_{0.005}^{(23)} s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}} = 0.165 \pm 0.355$, dvs. $[-0.17, 0.5]$. Nu är $0 \in [-0.17, 0.5]$ och därför kan man inte säga att det finns någon skillnad mellan de olika krominnehållen. Man har räknat 99% konfidensintervall för att få motsvarande resultat med testet i a).
- c) Både föreslår att det finns ingen skillnad mellan de två krominnehållen.
- d) $X_1 \sim N(\mu_1, \sigma)$ och $X_2 \sim N(\mu_2, \sigma)$

- 4) X_1, \dots, X_n är ett stickprov från $N(\mu, 2)$. Styrkan av testet är
 $P(H_0 \text{ förkastas} | H_1 \text{ sann}) = P\left(\frac{\bar{X}-10}{2/\sqrt{n}} \leq z_{0.01} | \mu = 9\right)$
 $= P\left(\frac{\bar{X}-9}{2/\sqrt{n}} \leq z_{0.01} + \frac{1}{2}\sqrt{n}\right) = \Phi\left(z_{0.01} + \frac{1}{2}\sqrt{n}\right) = 0.90 = \Phi(1.28)$,
där Φ är fördelningsfunktionen av den standardiserade normalfördelningen.
Nu är $z_{0.01} = -2.33$ (hitta $z_{0.01}$ sådant att $P(Z \leq z_{0.01}) = 0.01$, där $Z \sim N(0, 1)$), och då blir $-2.33 + \frac{1}{2}\sqrt{n} = 1.28$ och $n = 52.1$. Man kan säga att stickprovsstorleken måste vara minst 53.
- 5) a) $H_0 : \mu_1 = \mu_2$ mot $H_1 : \mu_1 \neq \mu_2$, där μ_1 och μ_2 är de sanna väntevärden av vattenabsorbansen för valstryck 10kg/cm² resp. 20kg/cm².
- b) Man har gjort ett parvist T -test och använt teststatistikan $T = \bar{D}/(S_d/\sqrt{n})$, där \bar{D} är medelvärdet av skillnaderna $D_i = X_{1i} - X_{2i}$ (där $X_{11}, \dots, X_{1,14}$ är vattenabsorbanserna för valstryck 10kg/cm² och $X_{21}, \dots, X_{2,14}$ de motsvarande värdena för valstryck 20kg/cm²) och $S_d^2 = \sum_{i=1}^{14} (D_i - \bar{D})^2/13$. Värdet för teststatistikan är 4.1028.
- c) H_0 förkastas. Det verkar som vattenabsorbansen är högre med valstryck 10kg/cm² än med 20kg/cm².
- d) Man antar att skillnaden D är normalfördelad.
- 6) a) När det finns ett linjärt samband mellan två variabler och man vill förklara en av dem m.h.a. den andra. Man kan använda residualplottar för att se om modellen är lämplig.
- b) Man vet att

$$\frac{B_0 - \beta_0}{S\sqrt{\sum x_i^2/n \sum (x_i - \bar{x})^2}} \sim T_{n-2}$$

om $Y_i \sim N(\beta_0 - \beta_1 x_i, \sigma)$ (se formelbladet för beteckningarna). Ett 95% konfidensintervall för β_0 : Man vet att

$$P(-t_{0.025} \leq \frac{B_0 - \beta_0}{S\sqrt{\sum x_i^2/n \sum (x_i - \bar{x})^2}} \leq t_{0.025}) = 0.95. \text{ Då får man att}$$

$$P\left(-t_{0.025} S\sqrt{\sum x_i^2/n \sum (x_i - \bar{x})^2} \leq B_0 - \beta_0 \leq t_{0.025} S\sqrt{\sum x_i^2/n \sum (x_i - \bar{x})^2}\right)$$

$$= P\left(B_0 - t_{0.025} S\sqrt{\sum x_i^2/n \sum (x_i - \bar{x})^2} \leq \beta_0 \leq B_0 + t_{0.025} S\sqrt{\sum x_i^2/n \sum (x_i - \bar{x})^2}\right)$$

$$= 0.95 \text{ och konfidensintervallet blir } B_0 \pm t_{0.025}^{(n-2)} S\sqrt{\sum x_i^2/n \sum (x_i - \bar{x})^2},$$

där B_0 (skattningen för β_0) och S hittar man i formelbladet.

- 7) a) Man testar $H_0 : \mu = 1.5\text{ppm}$ mot $H_0 : \mu > 1.5\text{ppm}$ på signifikansnivån 0.05 och använder ett ensidigt stickprovs T -test. Teststatistikan $T = (\bar{X} - 1.5)/(S/\sqrt{n})$ är T_7 -fördelad, $s = \sum_{i=1}^8 (x_i - \bar{x})^2/7 = 0.064$ och $\bar{x} = 1.47$. Man får att $t = -1.27$ och jämför det med $t_{0.05}^{(7)} = 1.895$. Nu är $t = -1.27 < 1.895 = t_{0.05}^{(7)}$ och man kan inte förkasta H_0 . Man kan inte säga att den genomsnittliga ammoniakkoncentrationen är större än 1.5ppm.
- b) Teckentestet för att testa $H_0 : M = 1.5\text{ppm}$ mot $H_0 : M > 1.5\text{ppm}$, där M är medianen av ammoniakkoncentrationen. Teststatistikan Q_+ är antalet positiva differenser $X_i - M$, vilket i vårt fall får värdet 3 (differensen som är noll räknas som negativ). Om H_0 är sann är $Q_+ \sim \text{Bin}(8, 0.5)$. p -värdet blir $P(Q_+ \geq 3 | H_0 \text{ sann, dvs. } M = 1.5) = 1 - P(Q_+ \leq 2) = 1 - (\frac{1}{2})^8(1 + 8 + 28) = 0.855$. p -värdet är större än signifikansnivån 0.05 och man kan inte förkasta H_0 . Medianen är inte större än 1.5ppm.
- c) a): $X \sim N(\mu, \sigma)$ och b): X har en kontinuerlig fördelning
- d) Ja. Det verkar som X var approximativt normalfördelad. Om resultaten hade varit olika, skulle man lita på det icke-parametriska testet.