



KTH Matematik

Avd. Matematisk statistik

TENTAMEN I SF1902 SANNOLIKHETSTEORI OCH STATISTIK  
MÅNDAGEN DEN 15:E AUGUSTI 2016 KL 8.00–13.00.

*Kursledare och examinator* : Björn-Olof Skytt, tel 790 8649.

*Tillåtna hjälpmedel*: miniräknare, lathund till statistikfunktioner på Texas Instruments-räknare (TI-82 Stats och högre) utan egna tillägg, läroboken av Blom m.fl. utan egna tillägg, formelsamlingen BETA utan egna tillägg.

Resonemang och uträkningar skall vara så utförliga och väl motiverade att de är lätta att följa. Numeriska svar skall anges med minst två siffrors noggrannhet.

### Uppgift 1

Låt  $A$  och  $B$  beteckna två händelser. Givet är  $P(A) = 3/5$ ,  $P(B|A) = 2/3$  och  $P(B|A^*) = 1/3$ , där  $A^*$  betecknar komplementet till händelsen  $A$ .

Avgör om  $A$  och  $B$  är beroende händelser.

### Uppgift 2

Ett spel går till på följande sätt: Man satsar 1 kr i en spelautomat. Om man vinner får man 3 gånger insatsen tillbaka, men om man förlorar så förlorar man sin satsade krona. Sannolikheten att vinna vid en spelomgång är 25%.

- Beräkna väntevärdet och standardavvikelsen för nettovinst om man spelar en omgång. Med nettovinst menas "utbetalt belopp minus insats".
- Beräkna med välmotiverad approximation sannolikheten att man går med nettovinst om man spelar 120 omgångar.

### Uppgift 3

GK-Motors utreder med egna resurser 10 av de bilolyckor som drabbat modellen GK-Roadrunner. Dessa tio olycksbilar är slumpmassigt valda ur ett mycket större antal ( $\approx 1000$ ) olycksbilar. Om man upptäcker att minst åtta av dessa 10 bilar har två eller fler skador hos kretskorten i den elektroniska servostyrningen, så kommer en hel årsproduktion att återkallas för åtgärd hos GKs återförsäljare. Man vet att sannolikheten = 0.6 för att antalet skador hos kretskorten i den elektroniska servostyrningen hos en bil ska vara högst ett.

Beräkna sannolikheten för att en hel årsproduktion av GK-Roadrunner kommer att återkallas.

### Uppgift 4

I en studie undersöktes hår- och ögonfärg hos 6800 slumpmässigt utvalda tyska män. Resultatet redovisas i följande tabell.

	Mörkt hår	Ljust hår
Bruna ögon	726	131
Grå eller gröna ögon	2133	999
Blå ögon	996	1815

Utför ett test på signifikansnivån 0.1% av om det finns ett statistiskt säkerställt samband mellan ögonfärg och hårfärg hos tyska män. Ange tydligt de uppställda hypoteserna och motivera tydligt vilken slutsats som dras från testet. (10 p)

### Uppgift 5

I den organiska kemin spelar smältpunktsbestämningar en stor roll för identifiering av en substans eller för bedömning av dennas renhet. För att undersöka om renheten hos två olika partier av hydrokinon skiljer sig åt tar man därför åtta prover från vardera partiet och bestämmer smältpunkten för vart och ett av dessa prov.

Smältpunkt								
Parti 1	174.0	173.5	173.0	173.5	171.5	172.4	173.5	173.5
Parti 2	173.0	173.0	172.0	173.0	171.0	172.0	171.0	172.0

Undersök på lämpligast sätt om om vi kan anta att partierna skiljer sig åt om vi antar att variationen mellan smältpunkterna i respektive prov är normalfördelad med en varians som är densamma för de båda partierna. Välj signifikansnivån 5%. Ange tydligt vilka de uppställda hypoteserna är och vad slutsatsen är.

### Uppgift 6

Nedan finns data från två olika gruvor A och B. Data visar silverhalten i ounces per ton malm hos respektive malmprov från de 9 malmproverna från gruva A och de 14 från gruva B.

Silverhalt														
Gruva A	32	41	33	28	18	36	19	29	51					
Gruva B	22	25	28	34	28	33	28	23	20	19	42	21	20	37

Data varierar på ett sådant sätt att de inte kan anses vara normalfördelade. Undersök på lämpligast sätt om om vi kan anta att gruvorna skiljer sig åt vad gäller silverhalten i malmen. Använd signifikansnivån 5% Ange tydligt vilka de uppställda hypoteserna är. Din slutsats skall tydligt motiveras.

### Uppgift 7

Gör en fullständig boxplott för de mätdata som kommer från gruva B i uppgift 6. Ange även kvartilavstånd och variationsbredd för dessa mätdata.



KTH Matematik

Avd. Matematisk statistik

LÖSNINGSFÖRSLAG TENTAMEN I SF1902 MATEMATISK STATISTIK.  
MÅNDAGEN DEN 15:E AUGUSTI 2016 KL 8.00–13.00

### Uppgift 1

Först bestäms

$$P(A \cap B) = P(B|A)P(A) = \frac{2}{3} \cdot \frac{3}{5} = \frac{2}{5}.$$

På samma sätt fås

$$P(A^* \cap B) = P(B|A^*)P(A^*) = \frac{1}{3} \cdot \left(1 - \frac{3}{5}\right) = \frac{1}{3} \cdot \frac{2}{5} = \frac{2}{15}.$$

Sålunda får vi att

$$P(B) = P(A \cap B) + P(A^* \cap B) = \frac{2}{5} + \frac{2}{15} = \frac{8}{15}.$$

Eftersom  $P(A \cap B) = 2/5$ , medan

$$P(A)P(B) = \frac{3}{5} \cdot \frac{8}{15} = \frac{8}{25} \neq \frac{2}{5},$$

så är händelserna  $A$  och  $B$  beroende.

### Uppgift 2

Låt  $X$  = nettovinsten vid en spelomgång.  $X$  antar värdet 2 med sannolikheten  $1/4$  och värdet  $-1$  med sannolikheten  $3/4$ .

a)

$$E(X) = 2 \cdot \frac{1}{4} + (-1) \cdot \frac{3}{4} = -\frac{1}{4}.$$

$$V(X) = E(X^2) - (E(X))^2 = 2^2 \cdot \frac{1}{4} + (-1)^2 \cdot \frac{3}{4} - \left(-\frac{1}{4}\right)^2 = \frac{27}{16}.$$

$$D(X) = \sqrt{\frac{27}{16}} \approx 1.30.$$

b) Låt  $X_i$  = nettovinst omgång  $i$ ,  $i = 1, 2, \dots, 120$ .  $X_i$ :na antas oberoende. Centrala gränsvärdes-satsen ger att  $Y = \sum_{i=1}^{120} X_i$  är approximativt normalfördelad med  $E(Y) = 120 \cdot E(X) = -30$  och  $V(Y) = 120 \cdot V(X) = 202.5$ , dvs  $Y \in N(-30, \sqrt{202.5})$ .

$$P(Y > 0) = P\left(\frac{Y + 30}{\sqrt{202.5}} > \frac{30}{\sqrt{202.5}}\right) \approx 1 - \Phi(2.11) \approx \underline{0.017}.$$

### Uppgift 3

Låt oss införa den stokastiska variabeln  $X$ , där  $X$  är antalet undersökta bilar som har minst två skador hos de elektroniska kretskorten i den elektroniska servostyrningen. Sannolikheten att en viss bil har minst två skador hos de elektroniska kretskorten i den elektroniska servostyrningen är 0.4 eftersom sannolikheten för högst en skada är 0.6. Eftersom vi kan anta att sannolikheten för minst två skador är densamma för varje bil medför detta att  $X \in \text{Bin}(10, 0.4)$

Vi söker nu  $P(X \geq 8) = 1 - P(X \leq 7) = [\text{se t.ex tab 6 i F.S.}] = 1 - 0.98771 = 0.01229$

Svar: Sannolikheten för att en hel årsproduktion av GK-Roadrunner kommer att återkallas är 1.23 %.

### Uppgift 4

Vi gör här ett homogenitetstest (avsnitt 14.3 i formelsamlingen). Nollhypotesen  $H_0$  är då att det inte finns ett samband mellan ögonfärg och hårfärg hos tyska män. Mothypotesen  $H_1$  är då att det finns ett sådant samband.

Vi gör här en tabell med observerade antal enligt

Observerade antal	Bruna ögon	Grå eller Gröna ögon	Blå ögon	Totalt
Mörkt hår	726	2133	996	3855
Ljust hår	131	999	1815	2945
Totalt	857	3132	2811	6800

Teststorheten blir

$$Q = \frac{(726 - \frac{857 \cdot 3855}{6800})^2}{\frac{857 \cdot 3855}{6800}} + \frac{(2133 - \frac{3132 \cdot 3855}{6800})^2}{\frac{2132 \cdot 3855}{6800}} + \frac{(996 - \frac{2811 \cdot 3855}{6800})^2}{\frac{2811 \cdot 3855}{6800}} +$$

$$+ \frac{(131 - \frac{857 \cdot 2945}{6800})^2}{\frac{857 \cdot 2945}{6800}} + \frac{(999 - \frac{3132 \cdot 2945}{6800})^2}{\frac{3132 \cdot 2945}{6800}} + \frac{(1815 - \frac{2811 \cdot 2945}{6800})^2}{\frac{2811 \cdot 2945}{6800}} = 957.6756$$

Om  $H_0$  är sann så är 957.6756 ett utfall från en stokastisk variabel som approximativt har en  $\chi^2$ -fördelning med  $(3 - 1)(2 - 1) = 2$  frihetsgrader. Eftersom  $\chi_{0.001}^2(2) = 13.8 < 957.6756$  så kan  $H_0$  förkastas på nivån 0.1%. Alternativt kan vi beräkna sannolikheten att en  $\chi^2(2)$ -variabel är större än eller lika med 957.6756 (`X2cdf` på en TI-räknare). Denna sannolikhet, dvs  $p$ -värdet för testet, är 0.000. Detta  $p$ -värde är så lågt att vi förkastar  $H_0$  på risknivån 0.1%. Både teststorheten och  $p$ -värdet fås direkt med funktionen `X2-Test` på en TI-räknare.

Svar: Vi drar slutsatsen att sambandet mellan hårfärg och ögonfärg för tyska män är statistiskt säkerställt på risknivån 0.1% .

### Uppgift 5

Vi har standardsituationen två oberoende stickprov från normalfördelningar med gemensam varians, dvs avsnitt 11.2 i formelsamlingen.

Låt  $x_1, \dots, x_8$  och  $y_1, \dots, y_8$  vara de uppmätta smältpunkterna i parti 1 respektive parti 2. Dessa är observationer av stokastiska variabler  $X_1, \dots, X_8$  respektive  $Y_1, \dots, Y_8$  (alla oberoende), med fördelningar  $N(\mu_X, \sigma)$  respektive  $N(\mu_Y, \sigma)$ .

Detta är hypotesprövning med två oberoende stickprov. Vi ställer upp hypoteserna  $H_0$  och  $H_1$

$$H_0 : \mu_X = \mu_Y$$

$$H_1 : \mu_X \neq \mu_Y$$

Vi bildar konfidensintervallet

$$I_{\mu_X - \mu_Y} = \left( \bar{x} - \bar{y} \pm t_{\alpha/2}(n_X + n_Y - 2) \cdot s \cdot \sqrt{\frac{1}{n_X} + \frac{1}{n_Y}} \right)$$

där

$$s^2 = \frac{(n_X - 1)s_X^2 + (n_Y - 1)s_Y^2}{n_X + n_Y - 2}.$$

Med  $n_X = n_Y = 8$ ,  $\bar{x} = 173.11$ ,  $\bar{y} = 172.12$ ,  $s_X = 0.80256$ ,  $s_Y = 0.83452$ ,  $s = 0.81870$ ,  $t_{0.025}(14) = 2.14$  får vi att  $I_{\mu_Y - \mu_X} = 0.99 \pm 0.88$ . Eftersom 0 inte ingår i konfidensintervallet kan man förkasta  $H_0$  på signifikansnivån 5%. Detta innebär att man med 5% felrisk kan påstå att det föreligger systematisk skillnad mellan de två partierna vad gäller smältpunkten.

Svar: Vi kan anta att partierna skiljer sig åt på risknivån 5 %.

### Uppgift 6

Här använder vi Wilcoxon's rangsummetest. Vi har hypoteserna

$H_0$  : De två gruvornas silverhalt skiljer sig inte åt.

$H_1$  : De två gruvornas silverhalt skiljer sig åt.

Om vi ordnar data i storleksordning fås

Gruva A	18	19	28	29	32	33	36	41	51					
Gruva B	19	20	20	21	22	23	25	28	28	28	33	34	37	42

Vi får följande ranger

Gruva A	1	2.5	11.5	14	15	16.5	19	21	23					
Gruva B	2.5	4.5	4.5	6	7	8	9	11.5	11.5	11.5	16.5	18	20	22

Vi har då att rangsummorna blir  $W_A = 123.5$ ,  $W_B = 152.5$ ,  $n_A = 9$  och  $n_B = 14$ . Detta ger oss att  $U_A = 78.5$  och  $U_B = 47.5$ . Vi ska testa på nivån 5% och det kritiska värdet blir då  $U_{0.05} = 31$ . Eftersom  $U_B$  är mindre än  $U_A$  jämförs  $U_B$  med det kritiska värdet. Eftersom  $U_B = 47.5 \geq U_{0.05} = 31$  förkastas inte  $H_0$  på nivån 5%.

Vi drar slutsatsen att vi inte kan säga att silverhalten skiljer sig åt mellan de två gruvorna

**Uppgift 7**

$x_{\min} = 19, x_{\max} = 42$ , så variationsbredden blir  $42 - 19 = 23$ .  
Medianen blir  $(x_7 + x_8)/2 = (25 + 28)/2 = 26.5$ .

$$Q_1 : 0.25 \cdot 14 = 3.5; 0.25 \cdot 14 + 1 = 4.5 \Rightarrow Q_1 = x_4 = 21$$

$$Q_3 : 0.75 \cdot 14 = 10.5; 0.75 \cdot 14 + 1 = 11.5 \Rightarrow Q_3 = x_{11} = 33.$$

Kvartilavståndet blir alltså  $Q_3 - Q_1 = 33 - 21 = 12$ .

**Uppgift 1**

a) Om vi här inför den stokastiska variabeln  $X_i$  där  $X_i$  är antal inkommande samtal till nattjouren natt i så gäller att  $X_i \in Po(\mu)$  där  $\mu = 0.3$ .

Alltså blir  $P(X_i = 0) = [\text{se tab 5 i F.S.}] = P(X_i \leq 0) = 0.74082$ .

Svar:  $P(X_i = 0) = 0.74082$ .

b) Om vi inför den stokastiska variabeln  $Y$  där  $Y$  är antal inkommande samtal till nattjouren under månaden så gäller att

$$Y = \sum_{i=1}^{30} X_i \in Po(30 \cdot 0.3) = Po(9)$$

Sökt är  $P(Y \geq 10) = [\text{se tab 5 i F.S.}] = 1 - P(Y \leq 9) = 1 - 0.58741 = 0.41259$ .

Svar:  $P(Y \geq 10) = 0.41259$ .

**Uppgift 2**

Här har vi Bayes sats.

Låt  $A, B, C, D$  beteckna händelserna att en lägenhet har ett, två, tre resp. fyra rum.

Låt  $V$  beteckna händelsen att en vattenskada inträffat. Då blir

$$\begin{aligned} P(B|V) &= \frac{P(B \cap V)}{P(V)} = \frac{P(V|B)P(B)}{P(V|A)P(A) + P(V|B)P(B) + P(V|C)P(C) + P(V|D)P(D)} = \\ &= \frac{0.05 \cdot \frac{1}{3}}{0.10 \cdot \frac{1}{6} + 0.05 \cdot \frac{1}{3} + 0.08 \cdot \frac{2}{5} + 0.15 \cdot \frac{1}{10}} = \frac{50}{241} = 0.207 \end{aligned}$$

Svar: Sannolikheten är 20.7% att det är en tvåa som har drabbats.

**Uppgift 3**

Eftersom det alltid gäller att

$$\int_{-\infty}^{\infty} f_X(x) dx = 1$$

fås  $c$  ur ekvationen

$$\int_2^8 c \cdot x^5 dx = 1$$

Vilket ger

$$\left[ \frac{c \cdot x^6}{6} \right]_2^8 = 1$$

Nu fås

$$c \cdot \frac{8^6 - 2^6}{6} = 1$$

Alltså blir

$$c = \frac{6}{8^6 - 2^6} = \frac{1}{43680} = 2.289 \cdot 10^{-5}$$

Detta medför att

$$P(6 < X < 12) = \int_6^8 c \cdot x^5 dx = \left[ \frac{c \cdot x^6}{6} \right]_6^8 = \frac{1}{43680} \frac{8^6 - 6^6}{6} = \frac{215488}{262080} = 0.822$$

Svar:  $c = 2.289 \cdot 10^{-5}$  och  $P(6 < X < 12) = 0.822$

**Uppgift 4**

Låt  $X_i$  vara den stokastiska variabeln *antal rum* för en på måfå observerad lägenhet. Vi får då

$$\mu = E[X_i] = \sum_{k=1}^4 k \cdot p_{X_i}(k) = 1 \frac{1}{6} + 2 \frac{1}{3} + 3 \frac{2}{5} + 4 \frac{1}{10} = \frac{146}{60} \approx 2.433$$

och

$$\sigma = D(X_i) = \sqrt{V(X_i)}$$

där

$$V(X_i) = E(X_i^2) - E^2(X_i) = E(X_i^2) - \left(\frac{146}{60}\right)^2$$

och

$$E(X_i^2) = \sum_{k=1}^4 k^2 \cdot p_{X_i}(k) = 1^2 \frac{1}{6} + 2^2 \frac{1}{3} + 3^2 \frac{2}{5} + 4^2 \frac{1}{10} = \frac{402}{60}$$

Detta medför att

$$V(X_i) = \frac{402}{60} - \left(\frac{146}{60}\right)^2 = \frac{2804}{3600} \approx 0.779$$

Vilket ger att

$$\sigma = D(X_i) = \sqrt{\frac{2804}{3600}} \approx 0.883$$

Låt nu

$$Y = \sum_{i=1}^{60} X_i$$

Vi antar nu att  $X_i$ :na är många och oberoende. Eftersom de dessutom är likafördelade gäller då enligt Centrala Gränsvärdesatsen C.G.S. att

$$Y \sim N(60\mu, \sigma\sqrt{60}) = N\left(60 \frac{146}{60}, \sqrt{\frac{2804}{3600}}\sqrt{60}\right) = N\left(146, \sqrt{\frac{2804}{60}}\right)$$

$$P(Y \geq 135) = P\left(\frac{Y - 146}{\sqrt{\frac{2804}{60}}} \geq \frac{135 - 146}{\sqrt{\frac{2804}{60}}}\right) = [Z = \frac{Y - 146}{\sqrt{\frac{2804}{60}}} \sim N(0, 1)] = P(Z \geq \frac{135 - 146}{\sqrt{\frac{2804}{60}}}) =$$

$$= 1 - P(Z \leq \frac{135 - 146}{\sqrt{\frac{2804}{60}}}) = 1 - \Phi\left(\frac{-11}{\sqrt{\frac{2804}{60}}}\right) = 1 - [1 - \Phi\left(\frac{11}{\sqrt{\frac{2804}{60}}}\right)] \approx \Phi(1.61) \approx 0.946$$

Svar: Sannolikheten att antalet rum är minst 135 är ungefär 94.6%

### Uppgift 5

$H_0$  är här att ingen statistiskt säkerställd förändring ägt rum i stödet för de rödgröna.  $H_1$  är att vi har en statistiskt säkerställd förändring Vi antar här att  $X_1$  är antalet som i april 2015 sade att de skulle röstat på de rödgröna och att  $X_2$  är antalet som i april 2016 sade att de skulle röstat på de rödgröna.  $X_1$  är då  $Bin(n_1, p_1)$  och  $X_2$  är  $Bin(n_2, p_2)$ . Vi vill nu bilda ett approximativt konfidensintervall för  $p_2 - p_1$ , men då måste  $X_1$  och  $X_2$  vara approximativt Normalfördelade. Villkoret för detta är att  $np(1-p) > 10$  för  $X_1$  och  $X_2$ . Vi skattar  $p_1$  med  $x_1/n_1 = 708/1649$  och  $p_2$  med  $x_2/n_2 = 686/1721$ . Vi får då att  $n_1 p_{1,obs}^* (1 - p_{1,obs}^*) = 404.02 > 10$  och  $n_2 p_{2,obs}^* (1 - p_{2,obs}^*) = 412.56 > 10$ . Villkoret är uppfyllt och vi kan bilda konfidensintervallet

$$I_{p_2 - p_1} = \left( p_{2,obs}^* - p_{1,obs}^* \pm \sqrt{p_{1,obs}^* (1 - p_{1,obs}^*) / n_1 + (p_{2,obs}^* (1 - p_{2,obs}^*) / n_2) \cdot \lambda_{\alpha/2}} \right).$$

Vi har en konfidensgrad på  $1 - \alpha = 0.95$  och då fås  $\lambda_{\alpha/2} = 1.9600$  och intervallet blir

$$-3.07 \cdot 10^{-2} \pm 17 \cdot 10^{-3} \cdot 1.96 = -3.07 \cdot 10^{-2} \pm 3.33 \cdot 10^{-2} = (-0.064, 0.0026).$$

0 tillhör intervallet och vi kan således inte förkasta  $H_0$  på risknivån 5%.

Vi drar slutsatsen att förändringen ej är statistiskt säkerställd på risknivån 5%.



### Uppgift 6

Vi gör här ett homogenitetstest (avsnitt 14.3 i formelsamlingen). Nollhypotesen  $H_0$  är då att fördelningen av stödet för de tre väljargrupperna är oförändrad mellan de båda undersökningstillfällena. Mothypotesen  $H_1$  är då att det skett en sådan förändring.

Vi gör här en tabell med observerade antal enligt

Observerade antal	Alliansen	Rödgröna	Övriga	Totalt
April 2016	724	686	311	1721
April 2015	672	708	269	1649
Totalt	1396	1394	580	3370

Teststorheten blir

$$Q = \frac{(724 - \frac{1721 \cdot 1396}{3370})^2}{\frac{1721 \cdot 1396}{3370}} + \frac{(686 - \frac{1721 \cdot 1394}{3370})^2}{\frac{1721 \cdot 1394}{3370}} + \frac{(311 - \frac{1721 \cdot 580}{3370})^2}{\frac{1721 \cdot 580}{3370}} +$$

$$+ \frac{(672 - \frac{1649 \cdot 1396}{3370})^2}{\frac{1649 \cdot 1396}{3370}} + \frac{(708 - \frac{1649 \cdot 1394}{3370})^2}{\frac{1649 \cdot 1394}{3370}} + \frac{(269 - \frac{1649 \cdot 580}{3370})^2}{\frac{1649 \cdot 580}{3370}} = 3.79$$

Om  $H_0$  är sann så är 3.79 ett utfall från en stokastisk variabel som approximativt har en  $\chi^2$ -fördelning med  $(3 - 1)(2 - 1) = 2$  frihetsgrader. Eftersom  $\chi_{0.05}^2(2) = 5.99 > 3.79$  så kan  $H_0$  inte förkastas på nivån 5%. Alternativt kan vi beräkna sannolikheten att en  $\chi^2(2)$ -variabel är större än eller lika med 3.79 (X2cdf på en TI-räknare). Denna sannolikhet, dvs  $p$ -värdet för testet, är 0.15. Detta  $p$ -värde är inte så lågt att vi förkastar  $H_0$  på risknivån 5%. Både teststorheten och  $p$ -värdet fås direkt med funktionen X2-Test på en TI-räknare.

Svar: Vi drar slutsatsen att någon förändring i stödet mellan de tre väljargrupperna ej är statistiskt säkerställd på risknivån 5%.

### Uppgift 7

$H_0$  är här att preparatet S inte har någon effekt på blodtrycket. Här använder vi oss av teckentestet. Vi inför den stokastiska variabeln  $Z$  som är antalet personer som får ett högre blodtryck efter behandling med S. Om  $H_0$  gäller ska  $Z \in \text{Bin}(n, 0.5) = \text{Bin}(16, 0.5)$ . Vi får alltså att

$$p\text{-värdet} = 2 \cdot P(Z \geq 11) = 2 \cdot P(Z \leq 5) = [\text{se tab 6; } x = 5, n = 16, p = 0.5] = 2 \cdot 0.1056 = 0.21012$$

d.v.s. 21.0%. Detta innebär att vi inte kan förkasta  $H_0$  på risknivån 10%.

Vi drar slutsatsen att förändringen ej är statistiskt säkerställd på risknivån 10%.