

# LINKÖPINGS UNIVERSITET

Matematiska institutionen

20 oktober 2020, kl. 14.00-18.00

Examinator: Jörg-Uwe Löbus

Tillåtna hjälpmedel är en räknare, formelsamling i matematisk statistisk utgiven av MAI, och ett ytterligare formelblad (framsida och baksida).

*Betygsgränser* 3: minst 8 poäng, 4: minst 11.5 poäng, 5: minst 15 poäng (av 18)

- (1) Låt  $X_1, \dots, X_{100}$  vara oberoende och binomialfördelade slumpvariabler där varje  $X_i$  är  $Bin(10, 0.4)$ -fördelad. Låt vidare  $Y_1, \dots, Y_{70}$  vara oberoende och Poissonfördelade slumpvariabler där varje  $Y_i$  är  $Po(6)$ -fördelad. Sätt  $X$  och  $Y$  till

$$X = \sum_{i=1}^{100} X_i \quad \text{and} \quad Y = \sum_{i=1}^{70} Y_i.$$

- (a) Använd centrala gränsvärdesatsen för att bestämma de approximativa fördelningarna av  $X$  och  $Y$ . (1.5p)
- (b) Använd resultatet av (a)-delen för att beräkna approximativt  $P(Y \geq X)$ . Om du inte kunde lösa (a)-delen använd istället  $X \sim N(390, 15)$  och  $Y \sim N(390, 20)$ . (1.5p)  
*Ledning:* Beakta  $P(Y \geq X) = P(Y - X \geq 0)$ . Bestäm fördelningen av  $Y - X$ .
- (2) År 2008 hade i Sverige 20% av befolkningen en årsinkomst som översteg 350.000 kronor och 10% av befolkningen hade en årsinkomst som översteg 550.000 kronor.
- (a) Om man fick veta (2008) att en svensk person tjänade mer än 350.000 kronor om året, vad är sannolikheten att personen tjänade mer än 550.000 kronor? (1.5p)
- (b) Bland svenska män hade 30% en årsinkomst som översteg 350.000 kronor. Antag att det bodde lika många kvinnor som män i Sverige. Om man fick veta att en svensk person tjänade mer än 350.000 kronor om året, vad är sannolikheten att det var en man? (1.5p)
- (3) En person åker först med buss 1, sedan med buss 2. Väntetiderna  $X$  och  $Y$  är oberoende och likformigt fördelade över intervallet  $(0, 10)$  respektive  $(0, 8)$ , där enheten är minuter. Bestäm sannolikheten att personen får vänta sammanlagt minst 16 minuter på de båda bussarna. (3p)  
*Ledning:* Den stokastiska vektorn  $(X, Y)$  är likformigt fördelad över ett rektangelformat område.
- (4) Ett företag som tillverkar skruvar vill se om man håller samma kvalitet som förra året. Då valde man slumpmässigt ut 1000 skruvar och fann 16 defekta. I år var man

mer ambitiös och valde ut 2000 skruvar, varvid 45 befanns vara defekta. Undersök med ett approximativt 95% konfidensintervall om andelar defekta skruvar ( $p_1$  resp  $p_2$ ) kan anses vara lika vid de två tillfällena.

- (a) Ange det generella (tvåsidiga) konfidensintervallet  $I_{p_2-p_1}$  för skillnaden i dessa andelar  $p_1$  och  $p_2$ . (1p)
  - (b) Beräkna ett tvåsidigt 95%-konfidensintervall för skillnaden i andelarna  $p_1$  och  $p_2$  baserat på uppgifterna i texten. (1.5p)
  - (c) Får man hävda att det är statistiskt säkerställt att det finns en skillnad mellan de båda andelarna, på konfidensnivå 95%? (0.5p)
- (5) Vid studier av syrsor har man funnit att frekvensen av vingrörelser växer med temperaturen. En modell för detta är:

$$y = \alpha + \beta \cdot x + \varepsilon, \quad \varepsilon \sim N(0, \sigma)$$

där  $x =$  temperatur i  $^{\circ}F$  och  $y =$  antal svängningar per sekund. I femton temperaturkammare med skilda temperaturer  $x$  uppmättes vingfrekvensen  $y$ .

- (a) Bestäm den skattade regressionslinjen  $y = \alpha_{obs}^* + \beta_{obs}^* \cdot x$ . (1p)
- (b) Pröva hypotesen vid signifikansnivån  $\alpha = 0.05$ ,

$$H_0 : \beta = 0 \quad \text{mot} \quad H_1 : \beta \neq 0.$$

(1p)

- (c) Bilda ett 95% konfidensintervall för  $\beta$ . (1p)

Räknehjälp:

$$\begin{aligned} \bar{x} &= 16.65, & \bar{y} &= 80.04 \\ S_{xx} &= 40.558 \\ S_{yy} &= 629.832 \\ S_{xy} &= 133.476 \end{aligned}$$

- (6) Låt  $X$  vara en stokastisk variabel med täthetsfunktion

$$f_X(x) = \begin{cases} \theta \cdot x^{\theta-1} & \text{för } 0 \leq x \leq 1 \\ 0 & \text{annars} \end{cases}$$

- (a) Bestäm väntevärdet och variansen för  $X$ . (1p)
- (b) Härled maximumlikelihood-skattningen av  $\theta$  baserad på oberoende observationer  $x_1, \dots, x_n$  av  $X$ . (2p)

## Lösningar

(1) (a) Vi har att

$$\begin{aligned} X_i \text{ är Bin}(10, 0.4) &\Rightarrow E(X_i) = 10 \cdot 0.4 = 4 & V(X_i) &= 10 \cdot 0.4 \cdot 0.6 = 2.4 \\ Y_i \text{ är Po}(6) &\Rightarrow E(Y_i) = 6 & V(Y_i) &= 6 \end{aligned}$$

Centrala gränsvärdessatsen ger att  $X$  är approximativt

$$N(100 \cdot 4, \sqrt{100 \cdot 2.4}) = N(400, 15.49) - \text{fördelad}$$

och  $Y$  är approximativt

$$N(70 \cdot 6, \sqrt{70 \cdot 6}) = N(420, 20.49) - \text{fördelad}.$$

(b) Vi skriver om den sökta sannolikheten:  $P(Y \geq X) = P(Y - X \geq 0) = 1 - P(Y - X < 0)$  Vad har  $Y - X$  för fördelning? Väntevärde och varians blir

$$\begin{aligned} E(Y - X) &= E(Y) - E(X) = 420 - 400 = 20 = \mu \\ V(Y - X) &= V(Y) + V(X) = 420 + 240 = 660 = \sigma^2 \end{aligned}$$

Normalisering till  $N(0, 1)$  ger

$$\begin{aligned} P(Y - X < 0) &= P\left(\frac{Y - X - \mu}{\sigma} < \frac{0 - \mu}{\sigma}\right) = P\left(Z < \frac{-20}{\sqrt{660}}\right) \\ &\approx \Phi(-0.78) = 1 - \Phi(0.78) = 1 - 0.7823 \end{aligned}$$

Därmed blir  $P(Y \geq X) \approx 1 - (1 - 0.7823) = 0.7823$

(2) (a) Låt  $G$  beteckna händelsen att personens årsinkomst översteg 350.000 kronor och  $H$  händelsen att årsinkomsten översteg 550.000 kronor. Vi har då att  $P(G) = 0.2$  och  $P(H) = 0.1$ . Sökt:  $P(H|G)$ . Eftersom  $H \subseteq G$ , så får vi

$$P(H|G) = \frac{P(G \cap H)}{P(G)} = \frac{P(H)}{P(G)} = \frac{0.1}{0.2} = \frac{1}{2}.$$

(b) Låt  $M$  beteckna händelsen att personen är man. Vi har då att  $P(M) = 0.5$  och  $P(G|M) = 0.3$ . Sökt:  $P(M|G)$ . Med hjälp av Bayes sats fås

$$P(M|G) = \frac{P(M \cap G)}{P(G)} = \frac{P(G|M)P(M)}{P(G)} = \frac{0.3 \cdot 0.5}{0.2} = 0.75.$$

(3) Sökt är  $P(X + Y \geq 16)$ . Den vita arean motsvarar  $\{X + Y \geq 16\}$ .



Paret av väntetider  $(X, Y)$  för de två bussarna är likformigt fördelat över rektangeln  $[0, 10] \times [0, 8]$ .

Vi får

$$P(X + Y \geq 16) = \frac{\text{vit area}}{\text{total area}} = \frac{2 \cdot 2/2}{80} = \frac{1}{40}.$$

(4) Låt  $X_i \sim \text{Bin}(n_i, p_i)$ ,  $i = 1, 2$ .

(a) Konfidensintervallet för  $p_2 - p_1$  är

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

där för  $i = 1, 2$

$x_i$  betecknar utfallet av  $X_i$  i en konkret undersökning,

$$p_{i\text{obs}}^* = \frac{x_i}{n_i}.$$

(b)

$$\begin{aligned} I_{p_2 - p_1} &= \left( p_{2\text{obs}}^* - p_{1\text{obs}}^* \pm \lambda_{\alpha/2} \sqrt{\frac{p_{1\text{obs}}^*(1 - p_{1\text{obs}}^*)}{n_1} + \frac{p_{2\text{obs}}^*(1 - p_{2\text{obs}}^*)}{n_2}} \right) \\ &= \left( \frac{45}{2000} - \frac{16}{2000} \pm 1.96 \cdot \sqrt{\frac{0.016 \cdot (1 - 0.016)}{1000} + \frac{0.0225 \cdot (1 - 0.0225)}{2000}} \right) \\ &= 0.0065 \pm 0.0101. \end{aligned}$$

(c) Eftersom  $0 \in I_{p_2 - p_1}$ , så är det med konfidensgrad 95% inte statistiskt säkerställt att det finns en skillnad.

(5) (a) Enligt formlarna är skattningarna

$$\begin{aligned}\beta_{obs}^* &= S_{xy}/S_{xx} = 133.476/40.558 = 3.29 \\ \alpha_{obs}^* &= \bar{y} - \beta_{obs}^* \cdot \bar{x} = 80.04 - 3.29 \cdot 16.65 = 25.26\end{aligned}$$

$$y = 25.26 + 3.29 \cdot x.$$

(b) Utfallet av teststorheten är

$$t = \frac{\beta_{obs}^* - 0}{\sigma_{obs}^*/\sqrt{S_{xx}}} = \frac{3.29}{3.83/\sqrt{40.558}} = 5.47$$

där

$$(\sigma_{obs}^*)^2 = \frac{1}{n-2} \left( S_{yy} - \frac{S_{xy}^2}{S_{xx}} \right) = 14.66$$

dvs.

$$\sigma_{obs}^* = 3.83.$$

Det kritiska området är

$$C = (-\infty, -t(n-2)_{\alpha/2}] \cup [t(n-2)_{\alpha/2}, +\infty) = (-\infty, -2.16] \cup [2.16, +\infty).$$

där  $n = 15$ . Eftersom  $t \in C$  så får vi förkasta  $H_0$ .

(c)

$$I_\beta = \beta_{obs}^* \pm t(n-2)_{\alpha/2} \cdot \frac{\sigma_{obs}^*}{\sqrt{S_{xx}}} = 3.29 \pm 1.3 = (1.99, 4.59).$$

(6) (a) Väntevärdet beräknas

$$E[X] = \int_{-\infty}^{\infty} x f(x) dx = \int_0^1 x \theta x^{\theta-1} dx = \left[ \theta \frac{x^{\theta+1}}{\theta+1} \right]_0^1 = \frac{\theta}{\theta+1}.$$

Dessutom får vi

$$E[X^2] = \int_{-\infty}^{\infty} x^2 f(x) dx = \int_0^1 x^2 \theta x^{\theta-1} dx = \left[ \theta \frac{x^{\theta+2}}{\theta+2} \right]_0^1 = \frac{\theta}{\theta+2}$$

och

$$Var(X) = E[X^2] - (E[X])^2 = \frac{\theta}{\theta+2} - \left( \frac{\theta}{\theta+1} \right)^2.$$

(b) Vi får likelihoodfunktionen

$$L(\theta) = \prod_{i=1}^n f_X(x_i; \theta) = \theta^n \cdot (x_1 \cdot \dots \cdot x_n)^{\theta-1}$$

och logaritmerar vi så får vi

$$\ln L(\theta) = n \ln \theta + (\theta - 1) \sum_{i=1}^n \ln x_i.$$

Deriverar vi detta,

$$\frac{d \ln L(\theta)}{d\theta} = \frac{n}{\theta} + \sum_{i=1}^n \ln x_i,$$

sätter derivatan = 0 och löser ut  $\theta$  så fås

$$\hat{\theta} = -\frac{n}{\sum_{i=1}^n \ln x_i}.$$

Kontroll ger även att andraderivatan är negativ,

$$\frac{d^2 \ln L(\theta)}{d\theta^2} = -\frac{n}{\theta^2},$$

vilket garanterar att det verkligen är en max-punkt för likelihoodfunktion vi hittat.