

LÖSNINGAR TILL

Matematisk statistik
 Matematikcentrum
 Lunds tekniska högskola
 Lunds universitet

Tentamen: 2017–10–24 kl 8⁰⁰–13⁰⁰
 FMSF70 — Matematisk statistik för B, K, N och BME, 7.5 hp
 MASB02 — Matematisk statistik för kemister, 7.5 hp

1. Låt $X_i \in Po(0.2)$ beteckna antalet monster under vardag i och $Y_i \in Po(0.1)$ antalet monster under helgdag i .

(a) Antal monster under en vecka ges av

$$Z = \sum_{i=1}^5 X_i + \sum_{i=1}^2 Y_i \quad \mathbf{E}(Z) = \sum_{i=1}^5 \mathbf{E}(X_i) + \sum_{i=1}^2 \mathbf{E}(Y_i) = 5 \cdot 0.2 + 2 \cdot 0.1 = 1.2$$

Eftersom summan av Poissonvariabler fortfarande är Poisson har vi att $Z \in Po(1.2)$

- (b) Vi söker $\mathbf{P}(Z \geq 0) = 1 - \mathbf{P}(Z = 0) = 1 - e^{-1.2} \approx 0.6988$
2. En lämplig modell är 2-stickprov med normalfördelade observationer enligt

$$\begin{aligned} X_i &\in N(\mu_x, \sigma) & Y_i &\in N(\mu_y, \sigma) \\ \mu_x^* &= \bar{x} = 69 & \mu_y^* &= \bar{y} = 58 \end{aligned}$$

Där vi vill testa $H_0 : \mu_x = \mu_y$ mot $H_1 : \mu_x > \mu_y$.

En poolad variansskattning ges av

$$s_p^2 = \frac{s_x^2(n_x - 1) + s_y^2(n_y - 1)}{n_x + n_y - 2} \approx 24.4545 \quad s_p = \sqrt{24.4545} = 4.9452$$

med $f = n_x + n_y - 2 = 11$ frihetsgrader. Skillanden i väntevärde är $\mu_x^* - \mu_y^* = 11$ med medelfel $\mathbf{d}(\mu_x^* - \mu_y^*) = s_p \sqrt{\frac{1}{n_x} + \frac{1}{n_y}}$. Ett lämpligt (nedåt begränsat) intervall ges nu av

$$I_{\mu_x - \mu_y} = \left(\mu_x^* - \mu_y^* - t_{0.05}(11) \mathbf{d}(\mu_x^* - \mu_y^*), \infty \right) = \left(11 - 1.80 \cdot 4.95 \cdot \sqrt{\frac{1}{8} + \frac{1}{5}}, \infty \right) = (5.94, \infty)$$

Eftersom intervallet **inte innehåller 0** kan vi **förkasta** H_0 . Man borde inte spendera natten i Innsmouth.

3. (a) a är kurvans skärning med y-axeln (i log-skala), i naturlig skala ges skärningen av e^a . b är hur snabbt $\log(\text{antal händelser})$ ändras per år (negativt värde anger en minskning, positivt en ökning). b kan också relateras till halverings- eller fördubblingstiden som $T = \log(2)/b$.
- (b) Att avgör om antalet underliga händelser avtar svarar mot att testa $H_0 : b = 0$ mot $H_1 : b < 0$. För en skattningen av b i linjärregression gäller $b^* \in N(b, \sigma^2/S_{tt})$ Vilket ger

$$\begin{aligned} I_b &= \left(-\infty, b^* + t_{0.05}(11 - 2) \mathbf{d}(b^*) \right) = \left(-\infty, b^* + t_{0.05}(11 - 2) \frac{s}{\sqrt{S_{tt}}} \right) = \\ &= \left(-\infty, -0.072 + 1.83 \cdot \frac{0.148}{\sqrt{110}} \right) = (-\infty, -0.0461) \end{aligned}$$

Det finns **en signifikant minskning**.

- (c) Det förväntade antalet händelser vid $t = 0$ ges av e^a . Det enklaste är att göra ett intervall för a som sen transformeras.

$$a^* \in N\left(a, \sigma^2 \left(\frac{1}{n} + \frac{\bar{t}^2}{S_{tt}}\right)\right)$$

$$d(a^*) = s \sqrt{\frac{1}{11} + \frac{7^2}{110}} = 0.1084$$

$$I_a = a^* \pm t_{0.025}(11-2)d(a^*) = 2.39 \pm 2.2622 \cdot 0.1084 = (2.1448, 2.6352)$$

$$I_{e^a} = (e^{2.1448}, e^{2.6352}) = (8.54, 13.95)$$

Alternativet är att göra ett konfidensintervall för $\mu(0)$ och sen transformera detta. Räkningarna blir i princip identiska.

- (d) Att avgöra när (efter hur lång tid) antalet händelser återgått till 1 per år svarar mot att göra ett kalibreringsintervall för $\log(1) = 0$. Standardräkningar ger:

$$t_0^* = \frac{\log(1) - a^*}{b^*} = \frac{-2.39}{-0.072} \approx 33.1944$$

$$I_{t_0} = t_0^* \pm t_{0.025}(11) \frac{s}{|b^*|} \sqrt{1 + \frac{1}{n} + \frac{(t_0^* - \bar{t})^2}{S_{tt}}} =$$

$$= t_0^* \pm 2.2622 \frac{0.148}{0.072} \sqrt{1 + \frac{1}{11} + \frac{(t_0^* - 7)^2}{110}} = t_0^* \pm 12.5882 = (20.6063, 45.7826)$$

4. Det verkar lämpligt att analysera experimentet som ett 2^2 -faktor försök. Lämplig modell är

$$y_{ijk} = \mu_{ij} + \varepsilon_{ijk}, \quad i = 1, 2; j = 1, 2; k = 1, \dots, 4 \quad \varepsilon_{ijk} \in N(0, \sigma^2)$$

$$\mu_{ij} = \mu \pm A \pm B \pm (\pm)AB$$

Där vi antagit att felen i varje observation är normalfördelade. Skattning av huvud- och samspelseffekter blir

$$A^* = \frac{-\mu_{11}^* + \mu_{21}^* - \mu_{12}^* + \mu_{22}^*}{2^2} = 1.2,$$

$$B^* = \frac{-\mu_{11}^* - \mu_{21}^* + \mu_{12}^* + \mu_{22}^*}{2^2} = -0.4,$$

$$(AB)^* = \frac{\mu_{11}^* - \mu_{21}^* - \mu_{12}^* + \mu_{22}^*}{2^2} = 0.5,$$

Den poolade variansskattningen är $s^2 = \frac{s_{11}^2 + s_{21}^2 + s_{12}^2 + s_{22}^2}{2^2} = 1.6825$ med $f = 2^2 \cdot (n-1) = 12$ frihetsgrader, och medelfelet för respektive effekt är

$$d(\text{effekt}) = \frac{s}{\sqrt{2^2 n}} = \sqrt{\frac{1.6825}{4 \cdot 4}} = 0.3243$$

Ett konfidensintervall för respektive effekt ges av

$$I_{\text{effekt}} = (\text{effekt})^* \pm t_{0.025}(f)d(\text{effekt}) = (\text{effekt})^* \pm 2.1788 \cdot 0.4835 = (\text{effekt})^* \pm 0.7065,$$

och effekterna är signifikanta om $|(\text{effekt})^*| > 0.7065$ (intervaller kommer då **inte** att innehålla 0).

Endast **huvudeffekt A** är **signifikant**. Tommy borde **rekommendera en blandning av vatten och etanol** eftersom enbart etanol har en signifikant positiv effekt.

5. En lämplig modell är att antalet monster månad i ges av D_i i Dunwich och A_i i Arkham. Med följande fördelningar

$$A_i \in Po(\mu_A), \quad \sum_{i=1}^{12} A_i = S_A \in Po(12\mu_A) \quad \text{och} \quad D_i \in Po(\mu_D), \quad \sum_{i=1}^6 D_i = S_D \in Po(6\mu_D)$$

där vi använt att summa av Poisson är Poisson och S betecknar summan av alla monster som observerats i respektive stad.

- (a) Lämpliga skattningar av monster frekvensen (μ) är nu

$$\mu_A^* = \frac{S_A}{12} = 2.5 \quad \text{och} \quad \mu_D^* = \frac{S_D}{6} = 5.1667$$

- (b) Eftersom $30 > 15$ och $31 > 15$ gäller CGS och vi kan normalapproximera Poissonfördelningarna vilket ger (för Arkham)

$$S_A \in Po(12\mu_A) \quad \text{CGS ger} \quad S_A \in N(12\mu_A, 12\mu_A) \quad \text{och} \quad \mu_A^* \in N\left(\mu_A, \frac{\mu_A}{12}\right)$$

eftersom

$$\mathbf{E}(\mu_A^*) = \mathbf{E}\left(\frac{S_A}{12}\right) = \frac{\mathbf{E}(S_A)}{12} = \mu_A \quad \text{och} \quad \mathbf{V}(\mu_A^*) = \mathbf{V}\left(\frac{S_A}{12}\right) = \frac{\mathbf{V}(S_A)}{12^2} = \frac{12\mu_A}{12^2} = \frac{\mu_A}{12}$$

Samma räkningar för Dunwich ger

$$\mu_D^* \in N\left(\mu_D, \frac{\mu_D}{6}\right)$$

- (c) För att undersöka om monsterfrekvensen är högre i Dunwich än i Arkham behöver vi testa $H_0 : \mu_A = \mu_D$ mot $H_1 : \mu_A < \mu_D$.

Om H_0 stämmer finns en gemmensam frekvens $\mu_0 = \mu_A = \mu_D$ så att

$$\sum_{i=1}^{12} A_i + \sum_{i=1}^6 D_i = S_A + S_D \in Po(18\mu_0) \quad \mu_0^* = \frac{30 + 31}{18} = 3.3889$$

Vi är intresserade av att testa om skillnaden $\mu_D - \mu_A > 0$. Eftersom μ_A^* och μ_D^* är approximativt normalfördelade är även $\mu_D^* - \mu_A^*$ approximativt normalfördelade med (under H_0)

$$\mathbf{E}(\mu_D^* - \mu_A^*) = \mu_D - \mu_A = 0$$

$$\mathbf{V}(\mu_D^* - \mu_A^*) = \mathbf{V}(\mu_D^*) + \mathbf{V}(\mu_A^*) = \frac{\mu_D}{6} + \frac{\mu_A}{12} = \mu_0 \left(\frac{1}{6} + \frac{1}{12}\right)$$

En teststorhet ges nu av

$$T = \frac{\mu_D^* - \mu_A^* - 0}{\mathbf{d}_{H_0}(\mu_D^* - \mu_A^*)} = \frac{2.667}{\sqrt{\mu_0^* \left(\frac{1}{6} + \frac{1}{12}\right)}} = \frac{2.667}{\sqrt{0.8472}} = 2.891$$

Eftersom $T > \lambda_{0.01} = 2.3263$ finns det en **signifikant skillnad**; vi kan **förkasta** H_0 .

6. (a) Linjärkombinationer av normalvariabler är fortfarande normalfördelade. Således är Z normalfördelad med

$$\mathbf{E}(Z) = \mathbf{E}(4X - 5Y + 2) = 4 \cdot \mathbf{E}(X) - 5 \cdot \mathbf{E}(Y) + 2 = -3$$

$$\mathbf{V}(Z) = \mathbf{V}(4X - 5Y + 2) = 4^2 \cdot \mathbf{V}(X) + (-5)^2 \cdot \mathbf{V}(Y) + 0 = 289 = 17^2$$

Vilket ger $Z \in N(-3, 17^2)$

(b) Symmetri i funktionen ger att $\mathbf{E}(X) = 0$, eller:

$$\begin{aligned}\mathbf{E}(X) &= \int_{-\infty}^{\infty} x \cdot f_X(x) \mathbf{d}x = \int_{-1}^0 x \cdot (1+x) \mathbf{d}x + \int_0^1 x \cdot (1-x) \mathbf{d}x = \\ &= \left[\frac{x^2}{2} + \frac{x^3}{3} \right]_{-1}^0 + \left[\frac{x^2}{2} - \frac{x^3}{3} \right]_0^1 = 0 - \left(\frac{1}{2} - \frac{1}{3} \right) + \left(\frac{1}{2} - \frac{1}{3} \right) - 0 = 0\end{aligned}$$

För variansen har vi att $\mathbf{V}(X) = \mathbf{E}(X^2) - \mathbf{E}(X)^2 = \mathbf{E}(X^2)$ (eftersom $\mathbf{E}(X) = 0$):

$$\begin{aligned}\mathbf{V}(X) = \mathbf{E}(X^2) &= \int_{-\infty}^{\infty} x^2 \cdot f_X(x) \mathbf{d}x = \int_{-1}^0 x^2 \cdot (1+x) \mathbf{d}x + \int_0^1 x^2 \cdot (1-x) \mathbf{d}x = \\ &= [\text{symmetri}] = 2 \cdot \int_0^1 x^2 \cdot (1-x) \mathbf{d}x = 2 \cdot \left[\frac{x^3}{3} - \frac{x^4}{4} \right]_0^1 = \frac{2}{12} = \frac{1}{6}\end{aligned}$$

(c) Standardintervall med känd varians ges av

$$I_\mu = \mu^* \pm \lambda_{0.025} \cdot \mathbf{D}(\mu^*) = \mu^* \pm \lambda_{0.025} \cdot \frac{\sigma}{\sqrt{n}}$$

Intervallbredden är $\Delta = 2 \cdot \lambda_{0.025} \cdot \sigma / \sqrt{n}$ vilket ger $n = (2 \cdot \lambda_{0.025} \cdot \sigma / \Delta)^2 = (2 \cdot 1.96 \cdot 3.5/2)^2 = 6.86^2 \approx 47.0579$. Det behövs minst $n = 48$ mätningar (behöver avrunda uppåt).

(d) Antalet 6:or är binomialfördelad, $X \in \text{Bin}(10, p)$. Eftersom H_0 förkastas om $x_{\text{obs}} \geq 5$ är signifikansen:

$$\alpha = \mathbf{P}(\text{förkasta } H_0 \text{ om } H_0 \text{ sann}) = \mathbf{P}(X \geq 5 | p = 1/6) = 1 - \mathbf{P}(X \leq 4 | p = 1/6) = 0.015$$

(e) Styrkan är $\mathbf{P}(\text{förkasta } H_0 \text{ om } \mu \text{ rätt värde})$ och styrkan öka i riktning mot H_1 och minska bort från H_1 . Vidare är signifikansnivån $= \alpha = 0.05 = \mathbf{P}(\text{förkasta } H_0 \text{ om } H_0 \text{ sann}) = b(-4)$

i) $b(-4) = \alpha$ och $b(-10) < \alpha < b(10)$.

ii) När mätfelet minskar blir det lättare att upptäcka avvikelser från H_0 (högre styrka); $b(10)$ ökar när σ minskar.

LYCKA TILL!