

1. (a) Vi har  $Z = X - Y \sim N(1, 2^2 + 3^2)$  och söker

$$P(Z > 0) = 1 - P(Z < 0) = 1 - \Phi\left(\frac{-1}{\sqrt{2^2 + 3^2}}\right) = 1 - \Phi(-0.2774) = 0.6092$$

- (b) Sannolikhetsfunktionen ges av  $f(k) = F(k) - F(k - 1)$  och blir alltså

k	1	2	3	4	5
f(k)	0.3	0.1	0.3	0.1	0.2

Väntevärdet beräknas som  $E(X) = \sum_{k=1}^5 kf(k) = 2.8$ . För att beräkna variansen beräknar vi först  $E(X^2) = \sum_{k=1}^5 k^2f(k) = 10$  och får  $V(X) = E(X^2) - E(X)^2 = 10 - 2.8^2 = 2.16$ .

2. (a) Vi beräknar differenserna  $D_i$  som mätningarna efter minus mätningarna före:

Observation $i$	1	2	3	4	5	6	7
Differens	3	-10	-9	3	-20	-5	-14

En skattning av  $\Delta$  ges av  $\bar{D} = -7.4286$ . Vi skattar variansen av  $D_i$  med stickprovsvariansen  $s^2 = 72.2857$ .

- (b) Ett 95% konfidensintervall för  $\Delta$  ges av

$$I_{\Delta} = \left(\bar{D} \pm t_{0.025}(6) \cdot \frac{s}{\sqrt{7}}\right) = (-7.4286 \pm 2.4469 \cdot 3.2135) = (-15.2917, 0.4346)$$

- (c) Eftersom testet är ensidigt beräknar vi ett ensidigt konfidensintervall

$$I_{\Delta} = \left(-\infty, \bar{D} + t_{0.05}(6) \cdot \frac{s}{\sqrt{7}}\right) = (-\infty, 1.9432 \cdot 3.2135) = (-\infty, -1.1842)$$

Eftersom intervallet inte täcker noll så kan vi förkasta  $H_0$ .

3. (a) Log-likelihood funktionen ges av

$$\begin{aligned} l(p) &= \log L(p) = \log \prod_{i=1}^{10} \binom{k_i - 1}{r - 1} p^r (1 - p)^{k_i - r} \\ &= \sum_{i=1}^{10} \log \left( \binom{k_i - 1}{r - 1} p^r (1 - p)^{k_i - r} \right) \\ &= \sum_{i=1}^{10} \left( \log \binom{k_i - 1}{r - 1} + r \log(p) + (k_i - r) \log(1 - p) \right) \end{aligned}$$

För att beräkna maximum likelihood-skattaren deriverar vi  $l(p)$ :

$$\begin{aligned} \frac{d}{dp} l(p) &= \sum_{i=1}^{10} \left( r \frac{1}{p} - (k_i - r) \frac{1}{1 - p} \right) \\ &= \frac{10r}{p} - \left( \sum_{i=1}^{10} k_i - 10r \right) \frac{1}{1 - p} \end{aligned}$$

Vi sätter derivatan till noll och löser ut  $p$ , detta ger skattningen

$$p = \frac{10r}{\sum_{i=1}^{10} k_i}$$

- (b) Den negativa binomialfördelningen  $NB(k, p)$  beskriver det totala antalet försök som vi måste göra tills att  $k$  har lyckats.
4. (a) Det är ett försök med så kallad ensidig indelning, där Faktor A är färgen på sidan. Vi ansätter modellen

$$y_{ij} = \mu + \alpha_i + \varepsilon_{ij},$$

där  $\varepsilon_{ij} \sim N(0, \sigma^2)$ ,  $\mu$  är det gemensamma väntevärdet för alla observationer, och  $\alpha_i$  anger förändringen i väntevärdet som orsakas av färgen på hemsidan.

- (b) Vi har

$$\bar{y} = \frac{1}{55 + 47 + 33 + 68}(55 \cdot 33 + 47 \cdot 27 + 33 \cdot 45 + 68 \cdot 40) = 35.9064$$

och

$$\begin{aligned} SS_A &= \sum_{ij} (\bar{y}_i - \bar{y})^2 \\ &= 55(33 - 35.9064)^2 + 47(27 - 35.9064)^2 + 33(45 - 35.9064)^2 + 68(40 - 35.9064)^2 \\ &= 8061.2 \end{aligned}$$

Med  $SS_E = SS_{Tot} - SS_A = 9938.8$  blir variansanalystabellen

Variation	Kvadratsumma	Frihetsgrader	Medelkvadratsumma	Teststorhet
Faktor A	8061.2	3	2687.1	53.8022
Residual	9938.8	199	49.9436	
Total	18000	202		

- (c) Vi vill utföra testet

$$H_0 : \alpha_1 = \alpha_2 = \alpha_3 = \alpha_4 = 0$$

$$H_1 : \text{åtminstone ett } \alpha_i \neq 0$$

Teststorheten är  $F(3, 196)$ -fördelad. Enligt formelsamlingen har vi

$$F_{0.05}(3, 199) \approx F_{0.05}(3, \infty) = 2.6507.$$

Det kritiska området för testet är  $C_\alpha = \{T : T > 2.6507\}$ . Eftersom  $T_{obs} = 53.8022$  ligger i  $C_\alpha$  kan vi förkasta nollhypotesen.

5. (a) Vi vill testa  $H_0 : \beta_1 = 0$  mot  $H_1 : \beta_1 \neq 0$ . Eftersom konfidensintervallet för  $\beta_1$  täcker noll så kan vi inte förkasta  $H_0$  på nivå  $\alpha = 0.05$ . Vi kan alltså inte hävda att avstånd har en signifikant påverkan.
- (b) Den totala variationen i datan,  $S_{yy}$ , kan delas upp i två delar:

$$S_{yy} = Q_0 + SSR,$$

där  $Q_0$  är residualvariationen och  $SSR$  är variationen som förklaras av linjen.  $R^2$  definieras som andelen av variationen som förklaras av linjen:

$$R^2 = \frac{SSR}{S_{yy}}.$$

- (c) Modell 2 passar bäst. Residualerna för den modellen ser oberoende ut och verkar inte uppvisa något speciell struktur. Residualerna för Modell 1 har en klar struktur som funktion av avstånd. Normalfördelningsplotten ser bättre ut för Modell 2 och den har högre förklaringsgrad än Modell 1.
- (d) Den förväntade logaritmerade effekten ges av  $\beta_0 + 7\beta_1 = -15.74$  och ett konfidensintervall beräknas som

$$I = \left( \beta_0 + 7\beta_1 \pm t_{0.025}(13)s \sqrt{\frac{1}{n} + \frac{(7 - 4.89)^2}{154.66}} \right) = (-17.47, -14.09)$$

- (e) (i) Sant, (ii) sant, (iii) falskt, (iv) sant.
6. (a) Den geometriska fördelningen beskriver fördelningen av antalet Bernoulliförsök tills det första lyckade. Den negativa binomialfördelningen  $NB(k, p)$  beskriver det totala antalet försök som vi måste göra tills att  $k$  har lyckats, och alltså är  $Ge(p)$ -fördelningen samma som  $NB(1, p)$ -fördelningen.
- (b) Vi har

$$\begin{aligned} E(Y_i) &= P(Y_i = 1) = P(X_i < 3) = P(X_i = 1) + P(X_i = 2) \\ &= p + p(1 - p) = 0.5 + 0.5^2 = 0.75. \end{aligned}$$

$Y$  är  $Bin(10, 0.75)$ -fördelad, och vi har därför att  $E(Y) = 10 \cdot 0.75 = 7.5$ .

- (c) Vi har  $E(Y) = 10(p + p(1 - p))$  och får momentskattningen av  $p$  genom att lösa ut  $p$  ur ekvationen  $E(Y) = 7$ :

$$10(p + p(1 - p)) = 7 \Rightarrow 2p - p^2 = 0.7 \Rightarrow p = 1 \pm \sqrt{1 - 0.7}.$$

En av de två lösningarna är större än 1 och alltså orimlig, vi har därför skattningen  $p = 1 - \sqrt{0.3} = 0.4523$ .

- (d) Vi vill beräkna sannolikheten att få något som är åtminstone så extremt som  $Y = 7$  givet att  $p = 0.5$ . Om  $p = 0.5$  har vi från (a) att  $Y \sim Bin(10, 0.75)$  och sannolikheten är därför

$$\begin{aligned} P(Y \geq 7|H_0) &= P(Y = 7) + P(Y = 8) + P(Y = 9) + P(Y = 10) \\ &= \binom{10}{7} 0.75^7 0.25^3 + \binom{10}{8} 0.75^8 0.25^2 + \binom{10}{9} 0.75^9 0.25^1 + \binom{10}{10} 0.75^{10} 0.25^0 \\ &= 0.2503 + 0.2816 + 0.1877 + 0.0563 = 0.7759 \end{aligned}$$

Eftersom p-värdet är större än  $\alpha$  kan vi inte förkasta  $H_0$ .