

Aufgabe	A17	A18	A19	A20	$\Sigma$
Punkte					

**Aufgabe 17.** Beh.:  $\varphi = \mathbb{1}_{A_k}$  mit  $k \in \mathbb{R}^+$  ist bester Test zum Niveau  $\mathbb{P}_0(A_k) \in [0, 1]$ .

*Beweis.* Sei  $\tilde{\varphi} = \mathbb{1}_{\tilde{A}}$  ein Test zum Niveau  $\mathbb{P}_0(A_k)$ , d.h.  $\mathbb{P}_0(\tilde{\varphi} = 1) = \mathbb{P}_0(\tilde{A}) \leq \mathbb{P}_0(A_k) = \mathbb{P}_0(\varphi = 1)$  (\*\*).

Z.z.:  $\mathbb{P}_1(\tilde{\varphi} = 0) = \mathbb{P}_1(\tilde{A}^c) \geq \mathbb{P}_1(A_k^c) = \mathbb{P}_1(\varphi = 0)$ .

Es ist  $x \in A_k \iff f_1(x) - kf_0(x) \geq 0$ , also  $x \in A_k^c \iff f_1(x) - kf_0(x) < 0$  (\*). Damit folgt

$$\begin{aligned} \mathbb{P}_1(A_k) - k\mathbb{P}_0(A_k) &= \int_{A_k} [f_1(x) - kf_0(x)] dx \\ &\geq \int_{A_k \cap \tilde{A}} [f_1(x) - kf_0(x)] dx \\ &\geq \int_{A_k \cap \tilde{A}} [f_1(x) - kf_0(x)] dx + \underbrace{\int_{A_k^c \cap \tilde{A}} [f_1(x) - kf_0(x)] dx}_{< 0 \text{ (*)}} \\ &= \int_{\tilde{A}} [f_1(x) - kf_0(x)] dx \\ &= \mathbb{P}_1(\tilde{A}) - k\mathbb{P}_0(\tilde{A}). \end{aligned}$$

Also folgt

$$\mathbb{P}_1(A_k) - \mathbb{P}_1(\tilde{A}) \geq k(\mathbb{P}_0(A_k) - \mathbb{P}_0(\tilde{A})) \stackrel{(**)}{\geq} 0.$$

Es ist also  $\mathbb{P}_1(A_k) \geq \mathbb{P}_1(\tilde{A})$ , insgesamt

$$\mathbb{P}_1(A_k^c) = 1 - \mathbb{P}_1(A_k) \leq 1 - \mathbb{P}_1(\tilde{A}) = \mathbb{P}_1(\tilde{A}^c).$$

Also Fehler 2. Art minimiert und damit  $\varphi$  bester Test zum Niveau  $\mathbb{P}_0(A_k)$ . □

**Aufgabe 18.** (a) Der Neyman-Pearson-Test  $\varphi: \mathbb{R} \rightarrow \{1, 0\}$  ist gegeben durch  $\mathbb{1}_{A_{k_\alpha}}$  mit

$$A_{k_\alpha} = \{x \in \mathbb{R} | f_1(x) \geq k_\alpha f_0(x)\} = \{x \in \mathbb{R} | f_1(x)/f_0(x) \geq k_\alpha\},$$

wobei wir zeigen werden, dass ein  $k_\alpha$  existiert mit  $\mathbb{P}_0(A_{k_\alpha}) = \alpha$ . Dabei ist der Likelihoodquotient  $L(x) = \frac{f_1(x)}{f_0(x)} = \frac{\lambda_0}{\lambda_1} e^{(\frac{1}{\lambda_0} - \frac{1}{\lambda_1})x}$  stetig und wegen  $\lambda_0 < \lambda_1 \implies \frac{1}{\lambda_0} > \frac{1}{\lambda_1}$  auch monoton wachsend. Insbesondere existiert zu jedem  $k_\alpha$  genau ein  $c_\alpha$  mit

$$A_{k_\alpha} = [c_\alpha, \infty).$$

Dann gilt

$$\alpha \stackrel{!}{=} \mathbb{P}_0(A_{k_\alpha}) = \int_{A_{k_\alpha}} f_0(x) dx = \int_{c_\alpha}^{\infty} \frac{1}{\lambda_0} e^{-\frac{1}{\lambda_0}x} dx = e^{-\frac{1}{\lambda_0}c_\alpha}$$

Daher gilt  $c_\alpha = -\lambda_0 \log(\alpha)$  und damit  $\varphi = \mathbb{1}_{[-\lambda_0 \log(\alpha), \infty)}$

(b) Offensichtlich ist also  $\varphi$  unabhängig von  $\lambda_1$ . Sei  $\lambda < \lambda_0$ . Dann gilt

$$\mathbb{P}_\lambda(A_{k_\alpha}) = \int_{-\lambda_0 \log(\alpha)}^{\infty} \frac{1}{\lambda} e^{-\frac{1}{\lambda}x} dx = e^{\frac{\lambda_0}{\lambda} \log(\alpha)} = \alpha^{\frac{\lambda_0}{\lambda}} < \alpha,$$

da  $\alpha < 1$ . Damit hält  $\varphi$  für  $H_0: \lambda \leq \lambda_0$  das Signifikanzniveau  $\alpha$  ein und ist folglich gleichmäßig bester Test mit  $H_1: \lambda > \lambda_0$ , da für alle  $\lambda_1 > \lambda_0$  nach dem Neyman-Pearson-Lemma  $\varphi$  ein bester Test ist.

(c) Die Forscher liegen falsch, wenn die Nullhypothese  $\lambda \leq \lambda_0$  wahr ist und sie diese ablehnen. Das ist also gerade ein Fehler erster Art und wir erhalten  $\alpha = 0.05$ . Damit ist  $\varphi = \mathbb{1}_{[-\lambda_0 \log(\alpha), \infty)} = \mathbb{1}_{[15,7917, \infty]}$ . Wegen  $\varphi(X) = \varphi(13) = 0$  publizieren sie ihre Ergebnisse nicht.

(d) Es gilt  $\mathcal{R}_\lambda = \mathcal{F}_\lambda^c = (0, \lambda)^c = [\lambda, \infty)$ . Die assoziierte Familie von Partitionen ist

$$\mathcal{H}_\lambda^0 := \{\tilde{\lambda} \in \mathbb{R}^+ : \lambda \in \mathcal{R}_{\tilde{\lambda}}\} = \{\tilde{\lambda} \in \mathbb{R}^+ : \lambda \geq \tilde{\lambda}\} = (-\infty, \tilde{\lambda}]$$

und analog

$$\mathcal{H}_\lambda^1 := \{\tilde{\lambda} \in \mathbb{R}^+ : \lambda \in \mathcal{F}_{\tilde{\lambda}}\} = \{\tilde{\lambda} \in \mathbb{R}^+ : \lambda < \tilde{\lambda}\} = (\tilde{\lambda}, \infty).$$

Nach Aufgabe b wissen wir, dass  $\varphi_\lambda = \mathbb{1}_{[-\lambda \log(\alpha)]}$  ein gleichmäßig bester Test zum Niveau  $\alpha$  mit Nullhypothese  $\mathcal{H}_\lambda^0$  gegen die Alternative  $\mathcal{H}_\lambda^1$  ist. Nach Satz 12.33 muss damit die assoziierte Bereichsschätzfunktion  $B$  ein gleichmäßig bester  $(1 - \alpha)$ -Konfidenzbereich sein. Die assoziierte Bereichsschätzfunktion ist gegeben durch

$$\begin{aligned} B(x) &= \{\lambda \in \mathbb{R}^+ : \varphi_\lambda(x) = 0\} \\ &= \{\lambda \in \mathbb{R}^+ : \mathbb{1}_{[-\lambda \log(\alpha), \infty)} = 0\} \\ &= \{\lambda \in \mathbb{R}^+ : x < -\lambda \log(\alpha)\} \end{aligned}$$

$\log(\alpha) < 0$

$$\begin{aligned} &= \{\lambda \in \mathbb{R}^+ : -x / \log(\alpha) < \lambda\} \\ &= \left(-\frac{x}{\log(\alpha)}, \infty\right) \end{aligned}$$

**Aufgabe 19.** (a) Beh.:  $\hat{\theta}_n(x) = (\bar{x}_n, \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2)$ .

*Beweis.* Betrachte für  $\sigma^2 > 0$ :

$$\begin{aligned} L(x, \mu, \sigma^2) &= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right) \\ l(x, \mu, \sigma^2) &= \log L \\ &= -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 - \frac{n}{2} \log(2\pi\sigma^2) \end{aligned}$$

Es genügt die Maxima von  $l = \log L$  zu betrachten, da der Logarithmus streng monoton wachsend ist. Betrachte den Gradienten bezüglich  $\mu$  und  $\sigma^2$ :

$$\nabla l(x, \mu, \sigma^2) = \left(\frac{1}{2\sigma^4} \sum_{i=1}^n 2(x_i - \mu), \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2 - \frac{n}{2} \frac{1}{\sigma^2}\right) \stackrel{!}{=} 0.$$

Damit folgt

$$\frac{1}{\sigma^4} \sum_{i=1}^n (x_i - \mu) = \frac{n}{\sigma^2} \implies \sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2.$$

Eingesetzt in die zweite Gleichung ergibt:

$$n \frac{\sum_{i=1}^n (x_i - \mu)}{\sum_{i=1}^n (x_i - \mu)^2} = 0 \implies \sum_{i=1}^n (x_i - \mu) = 0 \implies \sum_{i=1}^n x_i = n\mu \implies \mu = \bar{x}_n.$$

Damit folgt

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2.$$

Die Determinante der Hessematrix von  $l$  bezüglich  $\mu$  und  $\sigma^2$  ausgewertet bei  $\mu = \bar{x}_n$  ist  $\forall \sigma^2 > 0$ :

$$\begin{aligned} \det \left[ \begin{pmatrix} -\frac{n}{\sigma^4} & -\frac{1}{\sigma^6} \sum_{i=1}^n (x_i - \mu) \\ -\frac{1}{\sigma^6} \sum_{i=1}^n (x_i - \mu) & -\frac{1}{\sigma^6} \sum_{i=1}^n (x_i - \mu)^2 + \frac{n}{2} \frac{1}{\sigma^4} \end{pmatrix} \Big|_{\mu=\bar{x}_n} \right] &= \det \left[ \begin{pmatrix} -\frac{n}{\sigma^4} & 0 \\ 0 & \frac{n}{2\sigma^4} \end{pmatrix} \right] \\ &= -\underbrace{\frac{n^2}{2\sigma^6}}_{>0} < 0. \end{aligned}$$

Es liegt also ein (lokales) Maximum bei  $\theta = (\bar{x}_n, \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2)$  vor. Damit folgt die Behauptung.  $\square$

(b) Beh.:  $\hat{\theta}_n(x) = \frac{\bar{x}_n}{m}$ .

*Beweis.* Sei  $m \in \mathbb{N}$  fest. Betrachte wieder den Logarithmus der Likelihoodfunktion:

$$\begin{aligned} L(x, p) &= \prod_{i=1}^n p^{x_i} (1-p)^{m-x_i} \\ &= p^{n\bar{x}_n} (1-p)^{nm-n\bar{x}_n} \\ l(x, p) &= n\bar{x}_n \log(p) + n(m-\bar{x}_n) \log(1-p) \end{aligned}$$

Dann folgt

$$\frac{\partial l}{\partial p} = \frac{n\bar{x}_n}{p} - \frac{n(m-\bar{x}_n)}{1-p} \stackrel{!}{=} 0$$

Damit folgt direkt

$$p = \frac{\bar{x}_n}{m}$$

Dieses ist auch lokales Maximum da wegen  $0 \leq x_i \leq m \forall i \in \mathbb{N}$  auch  $0 \leq \bar{x}_n \leq m$  gilt und damit

$$\left. \frac{\partial^2 l}{\partial p^2} \right|_{p=\frac{\bar{x}_n}{m}} = -\frac{n\bar{x}_n}{p^2} - \frac{n(m-\bar{x}_n)}{(1-p)^2} \Big|_{p=\frac{\bar{x}_n}{m}} = -n \frac{m^2}{\bar{x}_n} - \frac{n \overbrace{(m-\bar{x}_n)}^{\geq 0}}{\left(1-\frac{\bar{x}_n}{m}\right)^2} < 0.$$

Da  $\frac{\bar{x}_n}{m}$  einzige Nullstelle von  $\frac{\partial l}{\partial p}$ , ist dieses auch globales Maximum. Damit folgt die Behauptung.  $\square$

**Aufgabe 20.** (a) Für die Zähldichte  $\mathbb{P}_{X_i}$  gilt

$$\mathbb{P}_{X_i} = \begin{cases} \mathbb{P}_{\text{Poi}_\lambda}(0) & | X_i = 0 \\ \sum_{i=1}^{\infty} \mathbb{P}_{\text{Poi}_\lambda}(i) & | X_i = 1 \end{cases} = \begin{cases} e^{-\lambda} & | X_i = 0 \\ 1 - e^{-\lambda} & | X_i = 1 \end{cases}$$

Für die Produktzähldichte erhalten wir daher

$$\prod_{i=1}^n \mathbb{P}_{X_i} = (1 - e^{-\lambda})^{\sum_{i=1}^n X_i} (e^{-\lambda})^{n - \sum_{i=1}^n X_i} = (1 - e^{-\lambda})^{n\bar{X}_n} (e^{-\lambda})^{n - n\bar{X}_n}$$

Daraus ergibt sich die Likelihoodfunktion

$$L(X, \lambda) = (1 - e^{-\lambda})^{n\bar{X}_n} e^{-n\lambda} e^{n\lambda\bar{X}_n} = (e^\lambda - 1)^{n\bar{X}_n} \cdot e^{-n\lambda},$$

die log-Likelihoodfunktion

$$l(X, \lambda) = n\bar{X}_n \log(e^\lambda - 1) - n\lambda,$$

sowie deren Ableitung

$$\frac{\partial}{\partial \lambda} l(X, \lambda) = n\bar{X}_n \frac{e^\lambda}{e^\lambda - 1} - n \stackrel{!}{=} 0,$$

von der wir direkt die Nullstellen berechnen um Extremstellen in  $L(X, \lambda)$  zu finden. Daraus folgern wir

$$\begin{aligned} \bar{X}_n e^{\hat{\lambda}_n} &= e^{\hat{\lambda}_n} - 1 \\ 1 - \bar{X}_n &= e^{-\hat{\lambda}_n} \\ \hat{\lambda}_n &= -\log(1 - \bar{X}_n). \end{aligned}$$

(b) Der Schätzer  $\hat{\lambda}_n$  existiert genau dann nicht, wenn  $\bar{X}_n = 1 \Leftrightarrow X_i = 1 \forall 1 \leq i \leq n$ . Es gilt

$$\mathbb{P}(X_1 = \dots = X_n = 1) = \prod_{i=1}^n \mathbb{P}_i(X_i = 1) = \prod_{i=1}^n (1 - e^{-\lambda}) = e^{-n\lambda} > 0.$$