

Um aus  $T, S$  und  $R$  zu vergleichen, kann man die Varianzen betrachten. Wünschenswert ist, dass ein asymptotisch erwartungstreu Schätzer eine kleine Varianz hat (warum?).

$$\text{Es gilt } \text{Var}_T(T) = \frac{\sigma^2}{(n+1)(n+2)} \quad \text{für } T = \max_{1 \leq i \leq n} X_i$$

$$\text{und } \text{Var}_T(S) = \frac{2\sigma^2}{(n+1)(n+2)} \quad (\text{ÜA})$$

$$\text{Also } \text{Var}_T(R) = \frac{4}{n^2} \sum_{i=1}^n \underbrace{\text{Var}_T(X_i)}_{\frac{\sigma^2}{12}} = \frac{\sigma^2}{3n}$$

In Bezug auf die Varianz ist  $R$  also ein deutlich schlechter als  $T$  und  $S$ .

Bem.:  $T, S$  und  $R$  sind asymptotisch erwartungstreu. Man kann also die Qualität von Schätzern nach verschiedenen Kriterien beurteilen (ML-Schätzer, Konsistenz, Erwartungstreu, kleine Varianz), die wir hier etwas systematischer behandeln wollen.

### 6.3 Das Maximum-Likelihood Prinzip

Das ML-Prinzip besteht darin, denjenigen Parameter bzw. dasjenige Modell zu wählen, das den beobachteten Daten die größte Likelihood gibt.

Def 6.10. (ML-Schätzer):

Sei  $(X, \mathcal{F}, (P_\theta; \theta \in \Theta))$  ein statistisches Modell.

a) Sei Abb.  $L: X \times \Theta \rightarrow [0, \infty)$

$$L_\theta(x) = L(x, \theta) = \begin{cases} P_\theta[\{x\}] & \text{falls } X \text{ diskret} \\ f_\theta(x) & \text{falls } X = \mathbb{R}^n, P_\theta \text{ hat Dichte } f_\theta \end{cases}$$

heißt Likelihood-Funktion.

(78)

(ii) Ein Schätzer  $T: X \rightarrow \Theta$  für  $\tau(\theta) = \theta$  heißt ML-Schätzer, falls

$$L(x, T(x)) = \max_{\theta \in \Theta} L(x, \theta) \quad \forall x \in X$$

Bsp 6.11: Ein auf dem Boden geworfener Reissackel fällt mit unbedeutender Winkel  $\theta \in [0, 1]$  auf die Spitze, ansonsten auf den Rücken.

Wir wollen  $\theta$  schätzen. Wir werfen  $n$  Mal und sehen, dass der Reissackel  $x$  Mal auf der Spitze landet.

Wir nehmen an, dass die Experimente unabhängig sind und modellieren sie über ein Binomialmodell, d.h.

$$X = \{0, 1, \dots, n\}$$

$$P_{\theta} \approx \text{Bin}(n, \theta), \quad \theta \in \Theta = [0, 1]$$

Die Likelihood-Fkt ist geg. durch  $L(x, \theta) = \binom{n}{x} \theta^x (1-\theta)^{n-x}$

Die Maximierung von  $L$  ist identisch mit der von  $\log L$ :

$$\frac{d}{d\theta} \log L(x, \theta) = \frac{x}{\theta} - \frac{n-x}{1-\theta}$$

und die rechte Seite ist fallend in  $\theta$  mit

$$\frac{d}{d\theta} \log L(x, \theta) = 0 \Leftrightarrow \theta = \frac{x}{n} \quad (\text{a. S. b. ist } \frac{x}{n} \text{ maximieren!})$$

$\Rightarrow T(x) = \frac{x}{n}$  ist ML-Schätzer.

Bsp 6.9 (Falschung, Game show Teil II).

Die Likelihood fkt ist geg. durch

$$L(x, \theta) = \begin{cases} \frac{1}{2^n} & , x = (x_1, \dots, x_n) \in \{0, \theta\}^n \\ 0 & , \text{sonst} \end{cases}$$

$\Rightarrow T(x) = \max_{1 \leq i \leq n} x_i$  ist ML-Schätzer.

Satz 6.12: Zu  $n \in \mathbb{N}$  betrachte das Produktmodell  $(\mathbb{R}^n, \mathcal{B}_n, (\mathcal{L}(\mu, \sigma^2))_{\mu, \sigma^2}, (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}_{>0} = \Theta)$ .  
 Dann ist der ML-Schätzer für  $\zeta(\mu, \sigma^2) = (\mu, \sigma^2)$  geg. durch  
 $T(x_1, \dots, x_n) = (\bar{x}_n, v_n)$ , wobei  $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$  der empirische Mittelwert und  $v_n = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2$  die empirische Varianz von  $x_1, \dots, x_n$  bedeuten.

L  
UD

Bew: Wir benutzen die Verschiebungsformel

$$\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2 + (\bar{x}_n - \mu)^2 \quad (*) \quad \forall \mu \in \mathbb{R}$$

Die Likelihood-Fkt ist geg. durch

$$L(x, (\mu, \sigma^2)) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left(-\sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}\right)$$

Wir wollen  $L(x, (\mu, \sigma^2))$  also  $(\mu, \sigma^2)$  max. machen,

also  $\sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}$  minimieren. Zunächst minimiere

wir  $\sum_{i=1}^n (x_i - \mu)^2$ . Mit (\*) gilt

$$\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 = \underbrace{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2}_{= (i)} + \underbrace{(\bar{x}_n - \mu)^2}_{= (ii)}$$

(i) hängt nicht von  $\mu$  ab, (ii) wird minimal für

$$\mu = \bar{x}_n \Rightarrow \hat{\mu}(x_1, \dots, x_n) = \bar{x}_n$$

Setzen wir dies in die Likelihood-Fkt ein, erhalte wir:

$$L(x, (\hat{\mu}, \sigma^2)) := \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left(-\sum_{i=1}^n \frac{(x_i - \bar{x}_n)^2}{2\sigma^2}\right)$$

Nun müssen wir  $v = \sigma^2$  so wählen, dass  $L(x, (\hat{\mu}, v))$

maximal wird. Wir gehen wieder zur Log-Likelihood-Fkt:

$$\log L(x, (\hat{\mu}, v)) = -\frac{n}{2} \log(2\pi v) - \frac{1}{2v} \sum_{i=1}^n (x_i - \bar{x}_n)^2$$

$$\frac{d}{dv} \log L(x, (\hat{\mu}, v)) = -\frac{n}{2v} + \frac{1}{2v^2} \sum_{i=1}^n (x_i - \bar{x}_n)^2 \stackrel{!}{=} 0$$

$$\Leftrightarrow v = v_n = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2$$

$$\text{und } \frac{d^2}{dv^2} \log L(x, (\hat{\mu}, v)) \Big|_{v=v_n} = \left( \frac{n}{2v^2} - \frac{1}{v^3} \sum_{i=1}^n (x_i - \bar{x}_n)^2 \right) \Big|_{v=v_n}$$

(P0)

$$= \frac{4}{\sqrt{n}} \left( \frac{1}{2} - 1 \right) = - \frac{4}{2\sqrt{n}} < 0 \Rightarrow$$

$\Rightarrow$  an der Stelle  $v = v_n$  liegt ein Maximum vor.

$\Rightarrow (\hat{\mu}, v_n) = (\bar{x}_n, v_n)$  ist der (kein eindeutige!) ML-Schätzer für  $(\mu, \sigma^2)$ .  $\square$

Bem.:  $x_1, x_2, \dots, x_n$  i.i.d. mit Dichte  $f_{\lambda}(x) = \frac{1}{2} e^{-|x-\lambda|}$ ,  $x \in \mathbb{R}$

Dann ist ein ML-Schätzer für  $\lambda$  geg. durch

$$T(x_1, \dots, x_n) = M(x_1, \dots, x_n) = \text{Median von } x_1, \dots, x_n \quad (\text{G17})$$

#### 6.4. Erwartungstreue und quadr. Fehler

Def 6.13: Seien  $(\mathcal{X}, \mathcal{F}, (\mathbb{P}_{\lambda}, \lambda \in \Theta))$  ein stat. Modell und

$\delta: \Theta \rightarrow \mathbb{R}$  eine reelle Kenngröße, Ein Schätzer  $T: \mathcal{X} \rightarrow \mathbb{R}$

für  $\delta$  heißt erwartungstreu, falls

$$\mathbb{E}_{\lambda}[T] = \delta(\lambda) \quad \forall \lambda \in \Theta$$

Die Differenz  $B_{\lambda}(T) = \mathbb{E}_{\lambda}[T] - \delta(\lambda)$  heißt der

Bias oder systematische Fehler von  $T$ .

Im Bsp 6.8 und 6.3 haben wir gesehen, dass ML-Schätzer nicht immer erwartungstreu sind. Auch die empirische Varianz ist i.A. kein erwartungstreu Schätzer.

Satz 6.14: Es sei  $(\mathbb{R}^d, \mathcal{B}_d, (\mathbb{P}_{\lambda}, \lambda \in \Theta))$  ein  $n$ -faches Produkt-

modell. Für jedes  $\lambda \in \Theta$  sei der Erwartungswert und

die Varianz  $V(\lambda)$  des Vektor  $\mathbb{P}_{\lambda}$  definiert und endlich

(d.h. falls eine ZV  $X$  die Vkg  $\mathbb{P}_{\lambda}$  hat gilt

$$\mathbb{E}_{\lambda}[X] = \mu(\lambda) < \infty, \text{Var}_{\lambda}[X] = V(\lambda) < \infty).$$

Dann sind der empirische Mittelwert  $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$  und

die korrigierte Stichprobenvarianz  $v_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2 = \frac{n}{n-1} v_n$

erwartungstreuen Schätzer für  $\mu(\mathcal{X})$  und  $V(\mathcal{X})$ .

Bew.: 1.  $E_{\mathcal{X}}[\bar{X}_n] = \frac{1}{n} \sum_{i=1}^n E_{\mathcal{X}}[X_i] = \frac{1}{n} \cdot n \cdot \mu(\mathcal{X}) = \mu(\mathcal{X})$

2. Da  $E_{\mathcal{X}}[X_i - \bar{X}_n] = 0$  folgt

$E_{\mathcal{X}}[V_n^*] = \frac{1}{n-1} \sum_{i=1}^n E_{\mathcal{X}}[(X_i - \bar{X}_n)^2]$   
 $= \frac{1}{n-1} \sum_{i=1}^n \text{Var}_{\mathcal{X}}(X_i - \bar{X}_n) = \frac{n}{n-1} \text{Var}_{\mathcal{X}}(X_1 - \bar{X}_n)$

$= \frac{n}{n-1} \text{Var}_{\mathcal{X}}\left(\frac{n-1}{n} X_1 - \frac{1}{n} \sum_{i=2}^n X_i\right)$

$\stackrel{\text{V}_n \text{ unabh. von } (X_2, \dots, X_n)}{=} \frac{n}{n-1} \left( \text{Var}_{\mathcal{X}}\left(\frac{n-1}{n} X_1\right) + \text{Var}_{\mathcal{X}}\left(\frac{1}{n} \sum_{i=2}^n X_i\right) \right)$

$= \frac{n}{n-1} \left( \left(\frac{n-1}{n}\right)^2 V(\mathcal{X}) + \frac{n-1}{n^2} V(\mathcal{X}) \right)$

$= \frac{n}{n-1} \cdot \frac{n-1}{n} V(\mathcal{X}) = V(\mathcal{X}). \quad \square$

Interpretive Erklärung:  $V_n$  unterschätzt  $V(\mathcal{X})$  systematisch, da die Streuung bereits durch die Wahl von  $\bar{X}_n$  (für  $\mu(\mathcal{X})$ ) klein gemacht wird.

Ein Maß für die Qualität von Schätzern ist die mittlere quadratische Fehler:

Def 6.15: Sei  $(\mathcal{X}, \mathcal{F}, (P_{\mathcal{X}}, \mathcal{X} \in \Theta))$  ein stat. Modell und

$\tau: \Theta \rightarrow \mathbb{R}$  eine reelle Kenngröße. Da mittlere quadr.


Fehler eines Schätzers  $T: \mathcal{X} \rightarrow \mathbb{R}$  für  $\tau$  ist geg. durch

$R_{\mathcal{X}}(T) := E_{\mathcal{X}}[(T - \tau(\mathcal{X}))^2]$


Man sieht leicht, dass

$R_{\mathcal{X}}(T) = \text{Var}_{\mathcal{X}}(T) + B_{\mathcal{X}}(T)^2$

Beweis:  $R_{\mathcal{X}}(T) = E_{\mathcal{X}}[T^2] - 2 E_{\mathcal{X}}[T] \tau(\mathcal{X}) + \tau(\mathcal{X})^2$   
 $= \text{Var}_{\mathcal{X}}(T) + E_{\mathcal{X}}[T]^2 - 2 E_{\mathcal{X}}[T] \tau(\mathcal{X}) + \tau(\mathcal{X})^2$   
 $= \text{Var}_{\mathcal{X}}(T) + B_{\mathcal{X}}(T)^2$



Bem 6.16: Das Kriterium, dass  $R_{est}(T)$  möglichst klein sein soll, liefert i.A. keine Totalordnung auf die Schätzer von  $\theta$ .



$T_1$  kann für gewisse Werte von  $\theta$  besser sein als  $T_2$  für andere schlechter.

Es gibt zwei Ansätze,  $T_1$  und  $T_2$  bzgl  $R_{est}(\cdot)$  zu vgl.

1. Bayes - Ansatz:

Geg. eine sogenannte  $\alpha$ -prior - VFG  $Q(d|\theta)$  auf  $\Theta$ , minimiere den erwarteten mittleren quadratischen Schätzfehler bzgl  $d_1, d_2$ , minimiere  $\int R_{est}(T) Q(d|\theta)$

2. Min: max - Ansatz (aus der Spiel Theorie)

minimiere:  $\max_{T \in \Theta} R_{est}(T)$  ("worst case analysis")

6.5. Varianzminimierende Schätzer

Wir betrachten Schätzer, die erwartungstreu sind und unter allen erwartungstreuen Schätzern optimal sind in dem Sinne, dass sie am wenigsten streuen.

Def. 6.17 Sei  $(X, \mathcal{F}, (P_\theta, \theta \in \Theta))$  ein stat. Modell,  $Z: \Theta \rightarrow \mathbb{R}$  eine Kenngröße. Ein erwartungstreuer Schätzer  $T$  für  $Z(\theta)$  heißt Varianz-minimierend oder glob. bester Schätzer, falls für jeden erwartungstreuen Schätzer  $S$  gilt:  $Var_\theta(T) \leq Var_\theta(S) \forall \theta \in \Theta$ .

Bem 6.18: Da  $T$  und  $S$  erwartungstreu, gilt

$$Var_\theta(T) = R_{est}(T), \quad Var_\theta(S) = R_{est}(S).$$

Es kann nicht erwartungstreue Schätzer geben mit  $Var_\theta(\tilde{T}) < Var_\theta(T)$

Def 6.15: Ein einparametrisches stat. Modell  $(\mathcal{X}, \mathcal{F}, (U_{\eta}, \eta \in \Theta))$  heißt regulär, falls  $\Theta$  ein offenes Intervall in  $\mathbb{R}$  ist (bzw.  $\Theta = \mathbb{R}$  ist erlaubt) und folgende Bedingungen erfüllt sind:

i) Die Likelihood-Fkt  $L$  ist auf  $\mathcal{X} \times \Theta$  strikt positiv und stetig nach  $\eta$  diff. bar. Insbesondere existiert die Energiefkt  $U_{\eta}$  geg. durch

$$U_{\eta}(x) = \frac{d}{d\eta} \log L(x, \eta) = \frac{\frac{d}{d\eta} L(x, \eta)}{L(x, \eta)}$$

ii) Für jedes  $\eta \in \Theta$  existiert die Varianz

$I(\eta) = \text{Var}_{\eta}(U_{\eta})$  und ist strikt positiv und es gibt die Vertauschungsrelation

$$\int_{\mathcal{X}} \frac{d}{d\eta} L(x, \eta) dx = \frac{d}{d\eta} \int_{\mathcal{X}} L(x, \eta) dx$$

(falls  $\mathcal{X}$  diskret:  $\sum_{x \in \mathcal{X}} \frac{d}{d\eta} L(x, \eta) = \frac{d}{d\eta} \sum_{x \in \mathcal{X}} L(x, \eta)$ )

Die Fkt  $I: \Theta \rightarrow (0, \infty)$  heißt die Fisher-Information des Modells.

Ben 6.20: Falls (ii) in Def 6.15 erfüllt ist, gilt:

$$E_{\eta}(U_{\eta}) = \int_{\mathcal{X}} \frac{\frac{d}{d\eta} L(x, \eta)}{L(x, \eta)} \cdot \underbrace{f_{\eta}(x)}_{=L(x, \eta)} dx = \int_{\mathcal{X}} \frac{d}{d\eta} L(x, \eta) dx$$

$$\stackrel{ii)}{=} \frac{d}{d\eta} \int_{\mathcal{X}} L(x, \eta) dx = 0.$$

$$\hookrightarrow I(\eta) = \text{Var}(U_{\eta}) = E_{\eta}(U_{\eta}^2) = \int_{\mathcal{X}} \left( \frac{\frac{d}{d\eta} L(x, \eta)}{L(x, \eta)} \right)^2 L(x, \eta) dx$$

$$\stackrel{f_{\eta}(x)=L(x, \eta)}{=} \int_{\mathcal{X}} \frac{\left( \frac{d}{d\eta} f_{\eta}(x) \right)^2}{f_{\eta}(x)} dx$$

(analog für den diskreten Fall).

Bsp 6.21: a)  $\mathcal{X} = \{0, 1, \dots\}$ ,  $\Theta = (0, \infty)$ ,  $P_{\eta} \sim \text{Poi}(\eta)$   
Fisher-Information?

(P4)  $L(x, \theta) = e^{-\theta} \frac{\theta^x}{x!}$   
 $\log L(x, \theta) = -\theta + x \log \theta - \log(x!)$

$U_{\theta}(x) = \frac{d}{d\theta} \log L(x, \theta) = -1 + \frac{x}{\theta}$

$I(\theta) = \text{Var}_{\theta}(U_{\theta}) = \frac{1}{\theta^2} \text{Var}_{\theta}(X) = \frac{1}{\theta^2} \cdot \theta = \frac{1}{\theta}$

b)  $\mathcal{X} = \mathbb{R}$ ,  $\Theta = \mathbb{R}$ ,  $\sigma > 0$  fix,  $P_{\theta} \sim \mathcal{N}(\mu, \sigma^2)$

$L(x, \theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\theta)^2}{2\sigma^2}\right)$

$U_{\theta}(x) = -\frac{x-\theta}{\sigma^2}$ ,  $I(\theta) = \frac{1}{\sigma^2} \quad \forall \theta \in \Theta$

Lemma 6.22: (Additivität der Fisher-Information).

Sei  $(\mathcal{X}, \mathcal{F}, (P_{\theta}, \theta \in \Theta))$  ein reguläres stat. Modell mit Fisher Info  $I$ . Dann hat das zugehörige  $n$ -fache Produktmodell Fisher Information  $I_n = n \cdot I$

Bew: Die Likelihood-Fkt  $L^{(n)}$  im Produktmodell ist geg. durch

$L^{(n)}(x, \theta) = \prod_{i=1}^n L(x_i, \theta)$  für  $x = (x_1, \dots, x_n)$

$\hookrightarrow U_{\theta}^{(n)} = \frac{d}{d\theta} \log L^{(n)}(x, \theta) = \sum_{i=1}^n U_{\theta}(x_i)$

$\hookrightarrow I_{\theta}^{(n)} = \text{Var}(U_{\theta}^{(n)}) \stackrel{\text{unabh.}}{=} \sum_{i=1}^n \text{Var}_{\theta}(U_{\theta}(x_i))$   
wg Produktmodell

$= n \text{Var}_{\theta}(U_{\theta}) = n I(\theta)$

Def 6.23: Ein erwartungstreuer Schätzer  $T$  für  $\tau(\theta)$  heißt regulär, falls für jedes  $\theta \in \Theta$  gilt:

$\int_{\mathcal{X}} T(x) \frac{d}{d\theta} L(x, \theta) dx = \frac{d}{d\theta} \int_{\mathcal{X}} T(x) L(x, \theta) dx$

Satz 6.24: (Informationsungl. von Rao-Cramér)

Sei  $(\mathcal{X}, \mathcal{F}, (P_{\theta}, \theta \in \Theta))$  ein reguläres stat. Modell,

$\tau: \Theta \rightarrow \mathbb{R}$  sei stet. diff.-bar Fkt mit  $\tau' \neq 0$



und  $T$  sei regulärer erwartungstreu Schätzer für  $\tau(\eta)$ . Dann gilt:

$$\text{Var}_{\eta}(T) \geq \frac{(\tau'(\eta))^2}{I(\eta)} \quad \forall \eta \in \Theta \quad (*)$$

"=" gilt für  $h \Leftrightarrow T - \tau(\eta) = \frac{\tau'(\eta)}{I(\eta)} U_{\eta} \quad \forall \eta \in \Theta,$

d.h. wenn die Likelihood-Fkt die Form

$$L(x, \eta) = e^{a(\eta)T(x) - b(\eta)} h(x) \quad (**)$$

hat, mit  $a: \Theta \rightarrow \mathbb{R}$ ,  $a$  Stammfkt von  $\frac{I}{\tau'}$ ,

$$h: \mathcal{X} \rightarrow (0, \infty) \text{ und } b(\eta) = \int_{\mathcal{X}} \exp(a(\eta)T(x)) \cdot h(x) dx.$$

Wir behandeln den skizzierten Fall.

Bew. Zuvor:

$$\text{Cov}_{\eta}(T, U_{\eta}) = \mathbb{E}_{\eta}[T \cdot U_{\eta}] - \mathbb{E}_{\eta}[T] \mathbb{E}_{\eta}[U_{\eta}] = 0 \quad (\text{Satz 6.20})$$

$$= \int_{\mathcal{X}} T(x) \left( \frac{d}{d\eta} \log L(x, \eta) \right) \underbrace{L(x, \eta)}_{= L(x, \eta)} dx$$

$$= \int_{\mathcal{X}} T(x) \frac{d}{d\eta} L(x, \eta) dx \stackrel{T \text{ regulär}}{=} \frac{d}{d\eta} \int_{\mathcal{X}} T(x) L(x, \eta) dx = \frac{d}{d\eta} \mathbb{E}_{\eta}[T]$$

$T$  erwartungstreu  $\frac{d}{d\eta} \mathbb{E}_{\eta}[T] = \tau'(\eta)$

Setze nun  $c(\eta) = \frac{\tau'(\eta)}{I(\eta)}$  und schreibe dann

$$0 \leq \text{Var}_{\eta}(T - c(\eta)U_{\eta})$$

$$= \text{Var}_{\eta}(T) + c(\eta)^2 \text{Var}_{\eta}(U_{\eta}) - 2c(\eta) \text{Cov}_{\eta}(T, U_{\eta})$$

$$= \text{Var}_{\eta}(T) + c(\eta)^2 I(\eta) - 2c(\eta) \tau'(\eta)$$

$$= \text{Var}_{\eta}(T) + \left( \frac{\tau'(\eta)}{I(\eta)} \right)^2 I(\eta) - 2 \frac{(\tau'(\eta))^2}{I(\eta)}$$

$$= \text{Var}_{\eta}(T) - \frac{(\tau'(\eta))^2}{I(\eta)} \Rightarrow (*)$$

(86) Zu  $\text{satz 6.1}$  gilt " $\Rightarrow$ "  $\Leftrightarrow T - c(\nu) U_\nu$  liegt  
 $P_\nu$  konstant ist und davon ~~konstant~~ insbesondere  
 mit ihrem Erzeugniswert übereinstimmt, der  
 wegen  $\mathcal{L}_\nu(U_\nu) = 0$  mit  $c(\nu)$  identisch ist. Da  
 das stat. Modell regulär ist folgt  $L(x, \nu) > 0$  und  

$$T(x) - c(\nu) = c(\nu) \underbrace{U_\nu(x)}_{\frac{d}{dx} \log L(x, \nu)} \quad \forall x \in \mathcal{X}, \nu \in \Theta.$$

Dies ist äquivalent zu

$$\frac{d}{dx} \log L(x, \nu) = \frac{I(\nu)}{c(\nu)} (T(x) - c(\nu)).$$

Mit Integration folgt (\*\*):

$$b(\nu) = - \int_{\Theta} c(\nu) \frac{I(\nu)}{c(\nu)} d\nu, \quad \log h(x) \text{ ist}$$

Integrationskonstante,  $a(\cdot)$  ist Stammfkt von  $\frac{I}{\mathcal{E}}$

$$\text{Außerdem gilt: } b(\nu) = \log \int_{\mathcal{X}} e^{a(\nu)T(x)} h(x) dx$$

Die Umkehrung folgt direkt: Falls  $L(x, \nu)$  die Form  
 $h(x)$  hat, so gilt

$$U_\nu = a'(\nu) T(x) - b'(\nu) = \frac{I(\nu)}{c(\nu)} T(x) - c(\nu) \frac{I(\nu)}{c(\nu)}$$

$$\text{also } T(x) - c(\nu) U_\nu = c(\nu) \quad \forall x \in \mathcal{X}, \nu \in \Theta.$$

(\*\*\*) gilt, da  $b(\nu) = \log \int_{\mathcal{X}} e^{a(\nu)T(x)} h(x) dx$ .

Damit:

$$b'(\nu) = \frac{\int_{\mathcal{X}} a'(\nu) T(x) e^{a(\nu)T(x)} h(x) dx}{\int_{\mathcal{X}} e^{a(\nu)T(x)} h(x) dx} = \frac{a'(\nu) \int_{\mathcal{X}} T(x) e^{a(\nu)T(x)} h(x) dx}{\int_{\mathcal{X}} e^{a(\nu)T(x)} h(x) dx} = a'(\nu) \frac{\int_{\mathcal{X}} T(x) e^{a(\nu)T(x)} h(x) dx}{\int_{\mathcal{X}} e^{a(\nu)T(x)} h(x) dx} = a'(\nu) \frac{\int_{\mathcal{X}} T(x) e^{a(\nu)T(x) - b(\nu)} h(x) dx}{\int_{\mathcal{X}} e^{a(\nu)T(x) - b(\nu)} h(x) dx} = a'(\nu) \frac{\int_{\mathcal{X}} T(x) e^{a(\nu)T(x) - b(\nu)} L(x, \nu) dx}{\int_{\mathcal{X}} e^{a(\nu)T(x) - b(\nu)} L(x, \nu) dx} = a'(\nu) \frac{\int_{\mathcal{X}} T(x) L(x, \nu) dx}{\int_{\mathcal{X}} L(x, \nu) dx} = a'(\nu) T(x)$$

Folgerungen aus Satz 6.24:

1. Bei  $n$ -fachen unabh. Wdh eines Experimentes, das durch ein reguläres, stat. Modell beschrieben wird, gilt für jeden reg. erwartungstreuen Schätzer  $T$  (vgl. Def. der Fisher Info)

$$\text{Var}_\tau(T) \geq \frac{1}{n} g(\tau)$$

mit einer geeigneten Fkt  $g: \Theta \rightarrow (0, \infty)$ . Im Bsp 6.8 (Taxi) und 6.9 (Ganzstow) hatten wir Schätzer gesehen, deren Varianz die Größenordnung  $\frac{1}{n^2}$  hat. Diese Modelle sind nicht regulär. (Prüfte wer nicht überall positiv!).

2. Falls die Fisher Info fkt von der Form  $k(x)$  in Satz 6.24 ist, so ist  $T$ , falls  $T$  erwartungstreu für  $\tau(\tau)$ , Varianz minimierend (zumindest in der Klasse der regulären Schätzer für  $\tau$ ). Um das weiteren (evidenten) Regularitätskriterium kann man zeigen, dass  $T \in$  dieser Situation varianzminimierend ist ( $\Rightarrow$  Vollst. "Statistik").

3. Sei  $\mathcal{M} = (\mathcal{X}, \mathcal{F}, (P_\tau; \tau \in \Theta))$  reg. stat. Modell mit Fisher Information  $I$ .  $\tau$  sei wie in Satz 6.24 und  $\tilde{T}$  sei reg. ~~est~~ erwartungstreu für  $\tau$ , der die Cramér-Rao Schranke erreicht, d.h.

$$\text{Var}_\tau(\tilde{T}) = \frac{\tau'(\tau)^2}{I(\tau)} \quad \tau \in \Theta$$

Sei  $\mathcal{M}'' = (\mathcal{X}'', \mathcal{F}'', (P''_\tau; \tau \in \Theta))$  das zugehörige Produktmodell. Dann ist

$$T(X) = \frac{1}{n} \sum_{i=1}^n \tilde{T}(X_i) \quad , \quad X = (X_1, \dots, X_n)$$

regulärer erwartungstreuer Schätzer für  $\tau$  in  $\mathcal{M}''$ , der die Cramér-Rao Schranke erreicht, d.h.

$$(88) \quad \text{Var}_{\theta}(\bar{T}) = \frac{\tau'(\eta\theta)^2}{n I(\eta\theta)} = \frac{\tau'(\eta\theta)^2}{I^{(n)}(\eta\theta)}$$

Bew. Nach Satz 6.24 folgt

$$L(x, \eta\theta) = e^{a(\eta\theta)T(x) - b(\eta\theta)} h(x)$$

Dann

$$L^{(n)}(x, \eta\theta) = e^{na(\eta\theta)T(x) - nb(\eta\theta)} \frac{h^n(x)}{n!}$$

und  $na(\eta\theta)$  ist Steigung von  $\frac{n I(\eta\theta)}{\tau'(\eta\theta)} = \frac{I^{(n)}(\eta\theta)}{\tau'(\eta\theta)}$

und damit gilt " $\Leftarrow$ " für  $T$  in  $(*)$  in Satz 6.24.  $\square$

Bsp 6.25: Poisson Modell.

Sei  $\mathcal{X} = \{0, 1, 2, \dots\}$ ,  $\Theta = (0, \infty)$ ,  $P_{\eta\theta} \sim \text{Poi}(\eta\theta)$

$$\hookrightarrow L(x, \eta\theta) = e^{-\eta\theta} \frac{(\eta\theta)^x}{x!} = e^{-\eta\theta} \times \log \eta\theta - \eta\theta \frac{1}{x!}$$

Dann hat  $L(x, \eta\theta)$  die gewünschte Form  $(*)$  in Satz 6.24

mit  $T(x) = x$ ,  $a(\eta\theta) = \log(\eta\theta)$ . Für  $\tau(\eta\theta) = \eta\theta$

gilt  $\tau'(\eta\theta) = 1$  und damit da  $I(\eta\theta) = \frac{1}{\eta\theta}$  (Bsp 6.21)

$$\text{folgt } a'(\eta\theta) = \frac{1}{\eta\theta} = \frac{I(\eta\theta)}{\tau'(\eta\theta)}$$

$\Rightarrow T(x) = x$  ist erwartungstreue Schätzung für  $\tau(\eta\theta) = \eta\theta$ ,  
 da die Rao-Cramer Schranke erreicht, insbesondere  
 ist  $T$  Varianz effizient.

Bsp 6.26:

$\mathcal{X} = \mathbb{R}$ ,  $\Theta = \mathbb{R}$ ,  $\sigma > 0$  fest,  $P_{\eta\theta} = \mathcal{N}(\eta\theta, \sigma^2)$

$$\text{Dann } L(x, \eta\theta) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\eta\theta)^2}{2\sigma^2}}$$

$$= \exp\left(-\frac{1}{2} \log(2\pi\sigma^2) - \frac{\eta\theta^2}{2\sigma^2} + \frac{\eta\theta}{\sigma^2} x - \frac{x^2}{2\sigma^2}\right)$$

Also von der Form  $(*)$  in Satz 6.24 mit  $T(x) = x$

$$a(\eta\theta) = \frac{\eta\theta}{\sigma^2}, \quad b(\eta\theta) = \frac{\eta\theta^2}{2\sigma^2} - \frac{1}{2} \log(2\pi\sigma^2), \quad h(x) = e^{-\frac{x^2}{2\sigma^2}}$$

Für  $Z(\eta) = \sigma^2$  gilt,  $a'(\eta) = \frac{1}{\sigma^2} = \frac{J(\eta)}{t'(\eta)}$  (vgl. Bsp 6.21 (ii))

Also ist  $T(x) = x$  erwartungstreu Schätzer für  $Z(\eta) = \sigma^2$  und Varianz-unverzerrt:

$$\text{Var}_\eta(T) = \frac{1}{\sigma^2}$$

### 6.6. Konsistenz:

Def 6.27: (Konsistente Folge von Schätzern)

Für jedes  $\eta \in \Theta$  sei  $(\mathcal{X}_n, \mathcal{F}_n, (P_{\eta,n}, \eta \in \Theta))$  ein stat. Modell mit Parametermenge  $\Theta$  und  $T_n$  ein Schätzer für ~~die~~ <sup>einmal</sup> Kenngröße  $Z$  im  $n$ -ten Modell.

Die Folge von Schätzern  $(T_n)_n$  heißt konsistent, falls für jedes  $\eta \in \Theta$  gilt:

$$\lim_{n \rightarrow \infty} P_{\eta,n} \{ |T_n - Z(\eta)| \geq \varepsilon \} = 0 \quad \forall \varepsilon > 0.$$

Bsp:  $(\mathcal{X}_n, \mathcal{F}_n, (P_{\eta,n}, \eta \in \Theta)) = (\mathcal{X}^n, \mathcal{F}^n, (P_\eta^n, \eta \in \Theta))$

Bsp 6.28: Daten des Bereiches von Zufallszahlen (vgl. Bsp 6.5)

$n$ -faches Produktmodell mit  $\mathcal{X} = [0, \infty)$ ,  $\mathcal{F} = \mathcal{B}_+$ ,

$P_\eta = \text{Unif}([0, \eta])$ . (haben gesehen, dass

$$T(x) = \max_{1 \leq i \leq n} x_i \quad \text{und} \quad P_\eta \{ T_n = \frac{2}{n} \sum_{i=1}^n x_i \} \text{ konsistente}$$

Folgen von Schätzern sind.

Allgemeiner gilt:

Ist  $T_n$  der empirische Mittelwert von  $n$  unabh.

Beob., so folgt die Menge von  $T_n$  aus dem schwachen

Gesetz der großen Zahlen. Das gilt ebenfalls für

die empirische Varianz.

Satz 6.23:

Sei  $(X, \mathcal{F}, (P_{\mathcal{H}}, \mathcal{L}(\mathcal{O}))$  stat. Modell und für jedes  $\mathcal{H}$  existiere der Erwartungswert  $\mu(\mathcal{H})$  und die Varianz  $V(\mathcal{H})$  und seien endlich (vgl. Satz 6.14). Wo nehmen an, dass für eine ZV  $X_{\mathcal{H}}$  mit V.Hg.  $P_{\mathcal{H}}$  das vierte Moment endlich ist:  $E_{\mathcal{H}} X_{\mathcal{H}}^4 < \infty \quad \forall \mathcal{H} \in \mathcal{O}$ .  
 Betrachte ein  $n$ -faches Produktmodell  $(X^n, \mathcal{F}^n, (P_{\mathcal{H}}^n, \mathcal{L}(\mathcal{O})))$  die Schätzer  $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n X_i$  für  $\mu(\mathcal{H})$  und  $v_n = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{x}_n)^2$  für  $V(\mathcal{H})$ . Dann sind die Folgen  $(\bar{x}_n)$  und  $(v_n)$  konsistent.

Bew. 1. Das schwache Gesetz der großen Zahlen impliziert

für alle  $\mathcal{H} \in \mathcal{O}$ , alle  $\varepsilon > 0$ , dass

$$P_{\mathcal{H}}^n [ |\bar{x}_n - \mu(\mathcal{H})| \geq \varepsilon ] \xrightarrow{n \rightarrow \infty} 0$$

2. Setze  $\tilde{v}_n = \frac{1}{n} \sum_{i=1}^n (X_i - \mu(\mathcal{H}))^2$ . Dann gilt

$$v_n = \tilde{v}_n - (\bar{x}_n - \mu(\mathcal{H}))^2 \quad (\text{vgl. Varianzformel Satz 6.12})$$

Das schwache Gesetz der großen Zahlen impliziert  $\forall \mathcal{H} \in \mathcal{O} \exists \delta > 0$

$$P_{\mathcal{H}}^n [ |\tilde{v}_n - V(\mathcal{H})| \geq \delta ] \xrightarrow{n \rightarrow \infty} 0$$

(mit  $Y_i = (X_i - \mu(\mathcal{H}))^2$ , beachte  $E_{\mathcal{H}}[Y_i^2] < \infty$  da das vierte Moment endlich ist).

Mit 1. folgt mit

$$|v_n - V(\mathcal{H})| \leq |v_n - \tilde{v}_n| + |\tilde{v}_n - V(\mathcal{H})| + (\bar{x}_n - \mu(\mathcal{H}))^2,$$

dass

$$P_{\mathcal{H}}^n [ |v_n - V(\mathcal{H})| \geq \varepsilon ] \leq P_{\mathcal{H}}^n [ |\tilde{v}_n - V(\mathcal{H})| \geq \frac{\varepsilon}{2} ] + P_{\mathcal{H}}^n [ |\bar{x}_n - \mu(\mathcal{H})|^2 \geq \frac{\varepsilon}{2} ] \xrightarrow{n \rightarrow \infty} 0$$

$$( |x+y| \geq \varepsilon \Rightarrow |x| \geq \frac{\varepsilon}{2} \text{ oder } |y| \geq \frac{\varepsilon}{2} ) \quad \square$$

Bew.:  $v_n^* = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{x}_n)^2$  ist ebenfalls konsistent für  $V(\mathcal{H})$ .

Bsp G.30: Sei  $(\mathcal{X}^n, \mathcal{F}^n, (P_{z,t}^n, z \in \mathbb{C}))$  das  $n$ -fache Produktmodell mit  $\mathcal{X} = \{0, 1, 2, \dots\}$ ,  $P_{z,t} = P_{z,t}(\mathcal{X}^n)$ ,  $\mathbb{C} = (0, \infty)$ . Dann gilt  $m_n(t) = E_{z,t}[\sum_{k=0}^n k^k \cdot \frac{z^k}{k!} e^{-z}]$  für alle  $z \in \mathbb{C}$ . Damit ist die Folge  $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n X_i$  eine konstante Folge von Zufallsvariablen für  $\tau(z) = z$ .

Bsp G.31: Wir wollen die mittlere Lebensdauer von Gleichbirnen schätzen. Gegeben sind  $n$  Messungen  $x_1, \dots, x_n$ , wobei  $X_i =$  Lebensdauer der  $i$ -ten Glöhbirne.

Sei  $(\mathcal{X}^n, \mathcal{F}^n, (P_{z,t}^n, z \in \mathbb{C}))$  das  $n$ -fache Produktmodell mit  $\mathcal{X} = (0, \infty)$ ,  $\mathcal{F} = \mathcal{B}_1$  (Borel  $\sigma$ -Algebra),  $P_{z,t}$  sei die Exponentialvergl. mit Parameter  $z$ , d.h.  $P_{z,t}$  hat Dichte  $f_{z,t}(x) = \begin{cases} ze^{-zx} & x \geq 0 \\ 0 & x < 0 \end{cases}$ .

Der Erwartungswert ist  $E_{z,t} X = \frac{1}{z}$ . Also folgt mit dem schwachen Gesetz der großen Zahlen  $\forall \varepsilon > 0$

$$P_{z,t}^n \left[ \left| \frac{1}{n} \sum_{i=1}^n X_i - \frac{1}{z} \right| \geq \varepsilon \right] \xrightarrow{t \rightarrow \infty} 0 \quad \forall z \in \mathbb{C}.$$

Damit ist  $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n X_i$  eine konstante Folge für  $\tau(z) = \frac{1}{z}$ . Die Stetigkeit der Funktion  $z \mapsto \frac{1}{z}$  für  $z \in (0, \infty)$  impliziert dann, dass für alle  $\varepsilon > 0$  ein  $\delta > 0$  existiert, so dass

$$\left| \frac{1}{\frac{1}{n} \sum_{i=1}^n X_i} - \frac{1}{z} \right| \leq \delta \Rightarrow \left| \frac{1}{\frac{1}{n} \sum_{i=1}^n X_i} - \frac{1}{z} \right| \leq \varepsilon$$

$\Rightarrow \forall \delta > 0$  folgt

$$P_{z,t}^n \left[ \left| \frac{1}{\frac{1}{n} \sum_{i=1}^n X_i} - \frac{1}{z} \right| \geq \delta \right]$$

$$= P_{z,t}^n \left[ \left| \frac{n}{\sum_{i=1}^n X_i} - z \right| \geq \delta \right] \xrightarrow{t \rightarrow \infty} 0 \quad \forall z \in \mathbb{C}.$$

92

Also ist  $(T_n)(X) = \left( \frac{4}{\sum_{i=1}^n X_i} \right)_n$  eine konstante Folge  
für  $\varepsilon(x) = x$ .

### 7. Konfidenzintervalle

Ein Schätzer für eine unbekannte Kenngröße liefert einen ersten Anhaltspunkt für den "wahren Wert", macht aber keine Aussage über die Zuverlässigkeit, d.h. über mögliche Abweichungen vom wahren Wert.

Betrachte wir nochmals Bsp 6.11: Ein Reissiegel fällt mit Wert  $x \in [0, 13]$  auf die Spitze,  $P_{13} \sim B_{13}(4, 1)$  und wir haben gesehen, dass  $T_n = \frac{X}{n}$  ein ML-Schätzer ist. Falls jedoch  $x$  irrational ist, so gilt  $T_n \neq 0 \forall n, \forall x$ .

Besser ist es also einen (von den Beob. ~~un~~ abhängige) Bereich anzugeben, in dem die Kenngröße mit vorgeg. Wert  $1-\alpha$  enthalten ist.

D.h. wir machen die Aussage ungegenauer, aber dafür zuverlässiger.

### Def 7.1 (Konfidenzintervalle):

Sei  $(X, \mathcal{D}, (P_x, x \in \Theta))$  ein stat. Modell,  $\tau: \Theta \rightarrow \mathbb{R}$  eine reelle Kenngröße und  $\alpha \in (0, 1)$  eine Fehlschwelle. Eine Familie  $(C(x))_{x \in \mathbb{R}}$  von Mengen  $C(x) \subseteq \mathbb{R}$  heißt ein Konfidenzintervall für  $\tau$  zum Intervallniveau  $\alpha$  (bzw. zum Sicherheitsniveau  $1-\alpha$ ), falls für jedes  $x \in \Theta$  gilt, dass

$$P_x[\tau(x) \in C(x)] \geq 1-\alpha, \quad [P_x[\tau(x) \in C(x)] = P_x[\tau(x) \in C(x) : \tau(x) \in C(x)]]$$


Falls jedes  $C(x)$  ein Intervall ist, so spricht man auch von einem Konfidenzintervall.



Beim 7.2. Konfidenzbereiche sind nur nicht leer, wenn sie klein sind. Genauso, sind  $(C(x))_{x \in X}$  und  $(C'(x))_{x \in X}$  nicht Konfidenzbereiche zum Intervallniveau  $\alpha$  mit  $C(x) \subseteq C'(x)$  für alle  $x$ . So ist  $(C(x))_{x \in X}$  zu bevorzugen.

§ 2 Konstruktion möglichst kleiner Konfidenzbereiche.

Wir betrachten nur  $\tau(\vartheta) = \vartheta$ . Betrachte folgende zweidimensionale Menge.  $C = \{ (x, \vartheta) \in X \times \Theta, \vartheta \in C(x) \}$



Für jedes  $\vartheta \in \Theta$  ist  $C_\vartheta = \{ x \in X : \vartheta \in C(x) \} = \{ x \in X : (x, \vartheta) \in C \}$  der horizontale Schnitt durch  $C$ .

Die Bed. = Def 7. §

$$P_{\vartheta} \{ \{ x \in X : \vartheta \in C(x) \} \} \geq 1 - \alpha \quad \forall \vartheta \in \Theta$$

$$\Leftrightarrow P_{\vartheta} \{ C_\vartheta \} \geq 1 - \alpha \quad \forall \vartheta \in \Theta.$$

Wir definieren also für jedes  $\vartheta \in \Theta$  eine (möglichst kleine) Menge  $C_\vartheta$ , so dass  $P_{\vartheta} \{ C_\vartheta \} \geq 1 - \alpha \quad \forall \vartheta \in \Theta$ .

Auf diese Art konstruieren wir eine Familie  $(C_\vartheta)_{\vartheta \in \Theta}$  von horizontalen Schnitten, und damit eine Menge  $C$ .

Dann sind die Mengen  $C(x) =$  vertikale Schnitte von  $C$  unsere Konfidenzbereiche. Ein Verfahren ist das folgende

folgende:

Konstruktion eines Konfidenzbereiches:

Sei  $\alpha > 0$  und sei  $L(x, \vartheta)$  gegeben.

1. Für jedes  $\vartheta \in \Theta$  konstruieren eine Menge der Form  $C_\vartheta = \{ x \in X : L(x, \vartheta) \geq c_\vartheta \}$ , wobei  $c_\vartheta > 0$

99


möglichst groß gewählt wird, so dass  $P_{\mathcal{H}}[C_{\mathcal{H}}] \geq 1-\alpha$  gilt.

2. Setze  $C = \{(x, \mathcal{H}) : x \in C_{\mathcal{H}}\}$ , dann bilden die  $x$ -Schnitte von  $C$ ,  $C(x) = \{\mathcal{H} \in \Theta : (x, \mathcal{H}) \in C\} = \{\mathcal{H} \in \Theta : x \in C_{\mathcal{H}}\}$  einen Konfidenzbereich für  $\varepsilon(\mathcal{H}) = \mathcal{H}$  wenn (obstehen kann).

Bsp. 3: Sei  $\sigma > 0$   $(\mathbb{R}, \mathcal{F}, (P_{\mathcal{H}}, \mathcal{H} \in \Theta)) = (\mathbb{R}, \mathcal{B}_{\mathbb{R}}, (N(\mu, \sigma^2))_{\mu \in \mathbb{R}})$

mit  $\Theta = \mathbb{R}$  - wir suchen Konfidenzbereich für  $\varepsilon(\mathcal{H}) = \mathcal{H}$ .

$$C_{\mathcal{H}} = \{x \in \mathbb{R} : f_{\mathcal{H}}(x) = I(x, \mathcal{H}) \geq d_{\mathcal{H}}\} = [x - \gamma, x + \gamma]$$



$$\text{Dann ist } C(x) = \{\mathcal{H} \in \Theta : x \in C_{\mathcal{H}}\} = \{\mathcal{H} \in \mathbb{R} : x - \gamma \leq x \leq x + \gamma\} = [x - \gamma, x + \gamma]$$

Also müssen wir  $\gamma$  so wählen, dass  $P_{\mathcal{H}}[\mathcal{H} \in C(x)] = P_{\mathcal{H}}[C_{\mathcal{H}}] \geq 1-\alpha$

Also  $P_{\mathcal{H}}([x - \gamma, x + \gamma]) \geq 1-\alpha$

Aber  $P_{\mathcal{H}}([x - \gamma, x + \gamma]) = P_0([- \gamma, \gamma])$

$$= \int_{-\gamma}^{\gamma} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2}{2\sigma^2}} dx \stackrel{!}{=} 1-\alpha \quad (\text{Dann ist } C(x) \text{ beliebig})$$

$$\Rightarrow \int_{-\infty}^{\gamma} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2}{2\sigma^2}} dx = \frac{\alpha}{2} \quad (*)$$

Wähle  $\gamma$  so  $(*)$  gilt. Dann ist  $(C(x))_{x \in \mathbb{R}} = ([x - \gamma, x + \gamma])_{x \in \mathbb{R}}$  der kleinste Konfidenzbereich für  $\varepsilon(\mathcal{H}) = \mathcal{H}$  wenn (obstehen kann).

Def 7.4: (Quantil)

Sei  $Q$  ein  $\mathcal{W}$ -maß auf  $(\mathbb{R}, \mathcal{B})$  und  $\alpha \in (0, 1)$ .

Jede Zahl  $q \in \mathbb{R}$  mit  $Q([- \infty, q]) \geq \alpha$  und

$Q([q, \infty)) \geq 1-\alpha$  heißt ein  $\alpha$ -Quantil von  $Q$ .

Ein  $\frac{1}{2}$ -Quantil von  $Q$  heißt Median von  $Q$

Quantile sind i.A. nicht eindeutig bestimmt. Falls  $Q$  eine Dichte  $f$  hat und  $\{x: f(x) > 0\}$  ein Intervall ist, so ist das  $\alpha$ -Quantil von  $Q$  die (eindeutig bestimmte) Zahl  $q$  mit  $\int_{-\infty}^q f(x) dx = \alpha$ .

Bsp 7.5 Emissionen kontrollieren

Von  $N=10$  Kraftwerken überprüfe wir  $n=4$  zufällig ausgewählte auf ihre Emissionswerte. Gemacht ist ein Kohlendioxidtest für die Anzahl  $X$  der Kraftwerke mit zu hohen Emissionswerten.  $X$  sei die Anzahl der Kraftwerke mit zu hohen Emissionswerten  $i$  der Stichprobe.

Also: Stichprobe der Größe 4 ohne Zurücklegen aus einer Urne mit roten Kugeln, von denen eine unbekannte Anzahl  $K$  schwarz ist.  $X = \#$  schwarze gezogene Kugeln

$X = \{0, 1, 2, 3, 4\}$ ,  $\Theta = \{0, 1, \dots, 10\}$

$W_{X|K} =$  hypergeom. Vert. mit Parametern  $N=10, n=4, K$   
d.h.  $L(x, K) = \frac{\binom{n}{x} \binom{N-n}{4-x}}{\binom{N}{4}}$  für  $x = 0, 1, \dots, 4$

Tabelle für  $\binom{10}{4} L(x, K)$ :

	$x=0$	$x=1$	$x=2$	$x=3$	$x=4$
$K=0$	210	0	0	0	0
$K=1$	126	84	0	0	0
$K=2$	70	112	28	0	0
$K=3$	35	105	69	7	0
$K=4$	15	80	30	24	1
$K=5$	5	50	100	50	5

(96)

Für  $r > 5$  mit Symm.  $L(x, r) = L(4-x, 10-r)$

Sei  $\alpha = \frac{1}{5}$  vorgegeben. Wo brauchen für jedes  $r$  so viele Werte  $x$ , bis  $\sum_{x \in C_r} L(x, r) \geq \frac{4}{5} = 1 - \alpha$ ,

also muss die Summe in einer Zeile (oben)  $\geq 168$  sein, da  $168 / (\frac{10}{4}) = \frac{168}{2.5} = \frac{4}{5}$ .

Damit sind  $C_r, r \in \mathcal{O}$  und  $C$  bestimmt.

$C(x)$  ergibt sich indem man in der  $x$ -ten Spalte diejenigen  $r$  betrachtet, deren Beitrag unbestrich sind, d.h.

$$C(0) = \{0, 1, 2\}$$

$$C(1) = \{1, 2, 3, 4, 5\}$$

$$C(2) = \{3, 4, 5, 6, 7\}$$

$$C(3) = \{5, 6, 7, 8, 9\}$$

$$C(4) = \{8, 9, 10\} \quad \dots$$

Bsp 7.6: Binomialmodell, vgl Bsp 6.11)

$$\mathcal{X} = \{0, 1, \dots, 4\}$$

$$P_r = \text{Bin}(4, r)$$

Gesucht ist ein Kaufbereich für  $\pi(r) = r$  vorgeg.

$\alpha \in (0, 1)$ . Wir wissen, dass  $T = \frac{X}{n}$  Varianz minimierender

Schätzer ist und machen daher den Ansatz:

$$C(x) = \left( \frac{x}{n} - \varepsilon, \frac{x}{n} + \varepsilon \right) \text{ wobei wir } \varepsilon \text{ so wählen,}$$

$$\text{dass } \underbrace{P_r \left[ \left\{ x, \left| \frac{x}{n} - r \right| \geq \varepsilon \right\} \right]}_{(*)} \leq \alpha$$

$$= \sum_{x: \left| \frac{x}{n} - r \right| \geq \varepsilon} \binom{4}{x} r^x (1-r)^{4-x} \leq \alpha$$

Wir suchen also das  $1 - \alpha$  Quantil für die

Verteilung von  $\left| \frac{X}{n} - p \right|$  wobei  $X \sim \text{Bin}(n, p)$ .

Zwei Möglichkeiten zur Näherung:

1) Tchebychev Ungleichung liefert:

$$\begin{aligned} P_p \left[ \left| \frac{X}{n} - p \right| \geq \varepsilon \right] &\leq \frac{\text{Var}(\frac{X}{n})}{n^2 \varepsilon^2} \\ &= \frac{p(1-p)}{n \varepsilon^2} \leq \frac{1}{4n \varepsilon^2} \quad \forall p \in \Theta \end{aligned}$$

Damit gilt ist (\*) erfüllt, falls  $\frac{1}{4n \varepsilon^2} < \alpha$ , d.h.

$$\varepsilon > \frac{1}{\sqrt{4n\alpha}}$$

Für  $n=1000$  und  $\alpha=0,025$  genügt  $\varepsilon > 0,1$

Da wir keine Eig. der Binomialver. benutzt haben, ist  $\varepsilon$  i.A. zu groß.

2) Zentraler Grenzwertsatz liefert

$$P_p \left[ \left| \frac{X}{n} - p \right| < \varepsilon \right] = P_p \left[ \left| \frac{X - np}{\sqrt{np(1-p)}} \right| < \varepsilon \frac{\sqrt{n}}{\sqrt{p(1-p)}} \right]$$

$$\stackrel{\text{ZGWS}}{\approx} 2 \Phi \left( \varepsilon \frac{\sqrt{n}}{\sqrt{p(1-p)}} \right) - 1 \stackrel{!}{\geq} 1 - \alpha$$

Kleine Klipse

(wegen  $\Phi(x) = 1 - \Phi(-x)$ ). Also wähle  $\varepsilon$  so, dass

$$\Phi \left( \varepsilon \frac{\sqrt{n}}{\sqrt{p(1-p)}} \right) \geq 1 - \frac{\alpha}{2}$$

Da wir  $p$  nicht kennen, wähle  $\varepsilon$  so, dass

$$\Phi(2\varepsilon\sqrt{n}) \geq 1 - \frac{\alpha}{2}$$

Für  $n=1000$  und  $\alpha=0,025$  ergibt sich

$$\Phi(2\varepsilon\sqrt{n}) \geq 0,9875$$

$$\leadsto 2\varepsilon\sqrt{n} \geq 2,24 \quad (\text{Tabelle})$$

$$\leadsto \varepsilon > 0,04 \quad \text{reicht!}$$