

Definition 6.2. Ein *statistisches Modell* ist ein Tripel $(\mathcal{M} =) (\mathcal{X}, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$, wo $\mathcal{X} \neq \emptyset$ Menge („Beobachtungs- oder Stichprobenraum“), $\mathcal{F} \subset 2^{\mathcal{X}}$ eine σ -Algebra, Θ eine Menge (mit $|\Theta| > 1$) und für jedes $\vartheta \in \Theta$ ist P_ϑ ein W'maß auf $(\mathcal{X}, \mathcal{F})$.

Das Modell \mathcal{M} heißt *parametrisch*, wenn $\Theta \subset \mathbb{R}^d$ für ein $d \in \mathbb{N}$, speziell *einparametrisch*, wenn $d = 1$.

\mathcal{M} heißt *diskret*, wenn \mathcal{X} abzählbar ist, \mathcal{M} heißt *stetig*, wenn $\mathcal{X} \subset \mathbb{R}^n$ und jedes P_ϑ eine Dichte $\rho_\vartheta : \mathcal{X} \rightarrow [0, \infty]$ besitzt.

Ein diskretes oder stetiges Modell heißt ein *Standardmodell*.

$(\mathcal{X}^n, \mathcal{F}^{\otimes n}, (P_\vartheta^{\otimes n})_{\vartheta \in \Theta})$ heißt das n -fache Produktmodell von \mathcal{M} (für Produktmaße vgl. Def. 2.21).

Definition 6.3. $(\mathcal{X}, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$ statistisches Modell, (S, \mathcal{A}) messbarer Raum.

1. Eine Zufallsvariable X (definiert auf $(\mathcal{X}, \mathcal{F})$ mit Werten in S , d.h. $X : \mathcal{X} \rightarrow S$ ist \mathcal{F} - \mathcal{A} -messbar) heißt eine *Statistik* (manchmal auch: „Stichprobe“).
2. Sei $\tau : \Theta \rightarrow \mathbb{R}$ eine reelle Kenngröße (oder „Parametermerkmal“), eine Statistik $T : \mathcal{X} \rightarrow \mathbb{R}$ heißt ein *Schätzer* (genauer: „Punktschätzer“) für τ .
3. Ein Schätzer T für τ heißt *erwartungstreu* (oder „unverzerrt“), wenn gilt


$$\forall \vartheta \in \Theta : \mathbb{E}_\vartheta[T] = \tau(\vartheta).$$

$b_\vartheta(T) := \mathbb{E}_\vartheta[T] - \tau(\vartheta)$ heißt die *Verzerrung* (englisch: bias) von T .

Die typische Konstruktion / Situation eines Schätzers ist $T = t(X)$ für eine Funktion $t : S \rightarrow \mathbb{R}$.

Man schreibt / benennt einen Schätzer für τ oft $\hat{\tau}$.

$(\mathcal{X}, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$ statistisches Modell, $X: \mathcal{X} \rightarrow S$ eine Statistik, $\tau: \Theta \rightarrow \mathbb{R}$ eine reelle Kenngröße (oder „Parametermerkmal“), $T: \mathcal{X} \rightarrow \mathbb{R}$ (hier definiert via $T = t \circ X$) ein Schätzer für τ



Schematische Darstellung eines Schätzers $T = t(X)$ für τ

Das Startbeispiel 6.1 in der Formalisierung von Definition 6.2 und 6.3 ausgedrückt:

- Statistisches Modell: $\mathcal{X} = \{0, 1\}^n$, $\mathcal{F} = 2^{\mathcal{X}}$, $\Theta = [0, 1]$, $P_\vartheta = \text{Ber}_\vartheta^{\otimes n}$
- Parametermerkmal: $\tau: \Theta \rightarrow \mathbb{R}$, $\tau(\vartheta) = \vartheta$
- Statistik: $S = \mathcal{X}$, $X = \text{Id}_{\mathcal{X}}$
- Schätzer: $T: \mathcal{X} \rightarrow \mathbb{R}$, $T((x_1, \dots, x_n)) = \frac{x_1 + \dots + x_n}{n}$

Dies ist ein Standardmodell im Sinne von Def. 6.2, es gilt $\mathbb{E}_\vartheta[T] = \vartheta = \tau(\vartheta)$ für alle $\vartheta \in [0, 1]$, d.h. T ist hier ein erwartungstreuer Schätzer für τ .

Beispiel 6.4 (Erwartungstreue Schätzer für Mittelwert und Varianz im Produktmodell). Für $\vartheta \in \Theta$ sei Q_ϑ ein W 'maß auf \mathbb{R} mit endlichem Mittelwert

$$m(\vartheta) := \int_{\mathbb{R}} x Q_\vartheta(dx)$$

und endlicher Varianz

$$v(\vartheta) := \int_{\mathbb{R}} (x - m(\vartheta))^2 Q_\vartheta(dx).$$

Unter P_ϑ seien X_1, \dots, X_n u.i.v., $X_i \sim Q_\vartheta$.

(In der Formalisierung von Definition 6.2 und 6.3 könnten wir wählen: $\mathcal{M} = (\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n), (P_\vartheta)_{\vartheta \in \Theta})$ mit $P_\vartheta = Q_\vartheta^{\otimes n}$ für $\vartheta \in \Theta$, als Statistik betrachten wir $X = (X_1, \dots, X_n)$ mit $X_i : \mathbb{R}^n \rightarrow \mathbb{R}$ die Projektion auf die i -te Koordinate.

Bemerge: dies ist u.U. kein parametrisches Modell, man könnte z.B.

$$\Theta := \left\{ Q : Q \text{ ist } W\text{'maß auf } \mathbb{R} \text{ mit } \int_{\mathbb{R}} x^2 Q(dx) < \infty \right\}$$

wählen.)

Dann ist

$$\begin{aligned} \bar{X} &:= \frac{1}{n} \sum_{i=1}^n X_i \quad \text{ein erwartungstreuer Schätzer für } m(\vartheta), \\ S^2 &:= \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \quad \text{ein erwartungstreuer Schätzer für } v(\vartheta). \end{aligned}$$

(In diesem Kontext heißt \bar{X} auch der empirische Mittelwert oder Stichprobenmittelwert, S^2 die korrigierte Stichprobenvarianz, vgl. auch die Diskussion in Kapitel 6.1 über deskriptive Statistik.)

Für $\vartheta \in \Theta$ gilt nämlich

$$\mathbb{E}_{\vartheta}[\bar{X}] = \frac{1}{n} \sum_{i=1}^n \mathbb{E}_{\vartheta}[X_i] = \frac{1}{n} \cdot n m(\vartheta) = m(\vartheta), \checkmark$$

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

$$\mathbb{E}_{\vartheta} \left[\sum_{i=1}^n (X_i - \bar{X})^2 \right] = n \mathbb{E}_{\vartheta} [(X_i - \bar{X})^2] = n \text{Var}_{\vartheta} [X_i - \bar{X}] \quad (+ 0^2)$$

$$= n \text{Var}_{\vartheta} \left[\frac{n-1}{n} X_1 - \frac{1}{n} \sum_{i=2}^n X_i \right] = n \left(\left(\frac{n-1}{n} \right)^2 \text{Var}_{\vartheta} [X_1] + \frac{n-1}{n^2} \text{Var}_{\vartheta} [X_1] \right)$$

$$= (n-1) \text{Var}_{\vartheta} [X_1],$$

u.a.

also

$$\mathbb{E}_{\vartheta} [S^2] = \frac{1}{n-1} \mathbb{E}_{\vartheta} \left[\sum_{i=1}^n (X_i - \bar{X})^2 \right] = v(\vartheta).$$

Beobachtung und Definition 6.5. Betrachten wir in der Situation von Beispiel 6.4 die Stichprobengröße n als variabel (formal: wir gehen zum unendlichen Produktmodell $\mathcal{M} = (\mathbb{R}^\infty, \mathcal{B}^{\otimes \infty}, (Q_\vartheta^{\otimes \infty})_{\vartheta \in \Theta})$ über (vgl. Beobachtung und Bericht 2.23), mit $X_i : \mathbb{R}^\infty \rightarrow \mathbb{R}$ Projektion auf i -te Koordinate).

Dann gilt für jedes $\vartheta \in \Theta$

$$\bar{X}_n := \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow[n \rightarrow \infty]{} m(\vartheta) \quad \text{stochastisch bzgl. } P_\vartheta \quad \text{und}$$

$$S_n^2 := \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2 \xrightarrow[n \rightarrow \infty]{} v(\vartheta) \quad \text{stochastisch bzgl. } P_\vartheta.$$

Man sagt: Diese (Folgen von) Schätzer(n) sind *konsistent*.

Für \bar{X}_n folgt dies direkt aus dem Gesetz der großen Zahlen (siehe Korollar 4.2), weiterhin ist

$$\begin{aligned} \frac{n-1}{n} S_n^2 &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2 = \left(\frac{1}{n} \sum_{i=1}^n X_i^2 \right) - 2 \left(\frac{1}{n} \sum_{i=1}^n X_i \bar{X}_n \right) + (\bar{X}_n)^2 = \left(\frac{1}{n} \sum_{i=1}^n X_i^2 \right) - (\bar{X}_n)^2 \\ &\xrightarrow[n \rightarrow \infty]{P_\vartheta} \int_{\mathbb{R}} x^2 Q_\vartheta(dx) - (m(\vartheta))^2 = v(\vartheta) \end{aligned}$$

stoch. unter P_ϑ
 $\xrightarrow[n \rightarrow \infty]{P_\vartheta} \mathbb{E}_\vartheta[X_i^2]$

gemäß dem Gesetz der großen Zahlen (siehe Bericht 4.8) zusammen mit Lemma 4.5 und obigem, wegen $\frac{n-1}{n} \rightarrow 1$ folgt mit Lemma 4.5 die Behauptung.

Bericht. Tatsächlich gilt sogar

$$\bar{X}_n \xrightarrow[n \rightarrow \infty]{} m(\vartheta) \quad P_\vartheta\text{-f.s.} \quad \text{und} \quad S_n^2 \xrightarrow[n \rightarrow \infty]{} v(\vartheta) \quad P_\vartheta\text{-f.s.}$$

(diese Schätzer sind auch „stark konsistent“).

Für \bar{X}_n folgt dies unter den Voraussetzungen von Beispiel 6.4 aus der Version des starken Gesetzes der großen Zahlen, die wir in Satz 4.6 bewiesen haben, für S_n^2 folgt dies aus Bericht 4.8.

6.2.1 Maximum-Likelihood-Schätzer

Definition 6.6. Sei $\mathcal{M} = (\mathcal{X}, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$ ein statistisches Standardmodell mit

Gewichten $\rho_\vartheta(\cdot)$ bzw. Dichte $\rho_\vartheta(\cdot)$ für $\vartheta \in \Theta$.

Die Funktion

$$\rho : \mathcal{X} \times \Theta \rightarrow [0, \infty)$$

ψ

$$(x, \vartheta) \mapsto \rho(x, \vartheta) := \rho_\vartheta(x)$$

heißt *Likelihood-Funktion* (manchmal auch „Plausibilitäts-Funktion“), für $x \in \mathcal{X}$ heißt

$$L_x : \Theta \rightarrow [0, \infty), \quad L_x(\vartheta) = \rho(x, \vartheta)$$

die *Likelihood-Funktion* zum Beobachtungswert x .

Ein Schätzer $T : \mathcal{X} \rightarrow \Theta$ heißt (ein) Maximum-Likelihood-Schätzer, wenn

$$(L_x(T(x))) = \rho(x, T(x)) = \max_{\vartheta \in \Theta} \rho(x, \vartheta) \quad \forall x \in \mathcal{X}$$

(auch kurz ML-Schätzer genannt, engl. MLE = maximum likelihood estimator).

Beispiel 6.7. I. („Rückfangmethode“, engl. “capture-recapture”) Ein Teich enthalte ϑ Fische (einer gewissen Art, $\vartheta \in \mathbb{N}$ ist der unbekannte Parameter), fange und markiere m , setze wieder aus. Wenn sich die markierten Fische gut verteilt haben, fange erneut n Fische.

Nehmen wir an, wir beobachten unter den erneut gefangenen x markierte Fische.

Formalisierung als statistisches Modell:

$$\mathcal{X} = \{0, 1, \dots, n\}, \Theta = \{(m \vee n), (m \vee n) + 1, (m \vee n) + 2, \dots\}, P_{\vartheta} = \text{Hyp}_{m, \vartheta - m, n}$$

Die Likelihood-Funktion ist

$$\rho(x, \vartheta) = \frac{\binom{m}{x} \binom{\vartheta - m}{n - x}}{\binom{\vartheta}{n}},$$

der ML-Schätzer ist

$$\widehat{\vartheta}_{\text{ML}} = T(x) = \left\lfloor \frac{n}{x} \cdot m \right\rfloor,$$

denn

$$\begin{aligned} \frac{\rho(x, \vartheta)}{\rho(x, \vartheta - 1)} &= \frac{\binom{\vartheta - m}{n - x} \binom{\vartheta - 1}{n}}{\binom{\vartheta}{n} \binom{\vartheta - 1 - m}{n - x}} \\ &= \frac{(\vartheta - m)(\vartheta - n)}{\vartheta(\vartheta - m - n + x)} = 1 - \frac{\vartheta x - mn}{\vartheta(\vartheta - m - n + x)} \begin{cases} > 1, & \vartheta < \frac{mn}{x}, \\ = 1, & \vartheta = \frac{mn}{x}, \\ < 1, & \vartheta > \frac{mn}{x} \end{cases} \end{aligned}$$

(beachte: stets ist $\vartheta - m \geq n - x$, es gibt im Teich mindestens so viele unmarkierte Fische wie in der Rückfang-Stichprobe).

Handwritten diagram illustrating the relationship between the observed proportion of marked fish in the sample and the estimated total number of fish in the pond. It shows the fraction $\frac{x}{n}$ is approximately equal to the fraction $\frac{m}{\vartheta}$, with a double-headed arrow indicating the equivalence. Below this, the formula $\vartheta \approx \frac{n}{x} \cdot m$ is written.

2. (Erfolgsw'keit im Binomialmodell)

$$\rho(x, \vartheta) = L_x(\vartheta) = \binom{n}{x} \vartheta^x (1 - \vartheta)^{n-x}, \quad (P_\vartheta = \text{Bin}_{n,\vartheta} \text{ f\"ur } \theta \in \Theta = [0, 1], x \in \mathcal{X} = \{0, 1, \dots, n\}),$$

$$\begin{aligned} \frac{d}{d\vartheta} \log L_x(\vartheta) &= \frac{d}{d\vartheta} \left(\log \binom{n}{x} + x \log \vartheta + (n - x) \log(1 - \vartheta) \right) \\ &= \frac{x}{\vartheta} - \frac{n - x}{1 - \vartheta} = 0 \iff \vartheta = \frac{x}{n}, \end{aligned}$$

d.h. hier ist $\widehat{\vartheta}_{\text{ML}} = \frac{x}{n}$.

(Es ist $\frac{d}{d\vartheta} \log L_x(\vartheta) > 0$ f\"ur $\vartheta < x/n$ und $\frac{d}{d\vartheta} \log L_x(\vartheta) < 0$ f\"ur $\vartheta > x/n$, d.h. es handelt sich tats\"achlich um ein Maximum; Inspektion zeigt, dass auch in den Randf\"allen $x = 0$ und $x = n$ $\widehat{\vartheta}_{\text{ML}} = \frac{x}{n}$ gilt.)

3. (Normales Modell mit bekannter Varianz) n Beobachtungen seien u.i.v. $\sim \mathcal{N}_{\vartheta, \sigma^2}$, $\sigma^2 > 0$ sei bekannt.

Mit $x = (x_1, \dots, x_n) \in \mathbb{R}^n$ ist

$$\begin{aligned} \rho(x, \vartheta) = L_x(\vartheta) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x_i - \vartheta)^2}{2\sigma^2}\right) \\ &= (2\pi\sigma^2)^{-n/2} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \vartheta)^2\right) \end{aligned}$$

($\Theta = \mathbb{R}$,
 $P_{\vartheta} = \mathcal{N}_{\vartheta, \sigma^2}$)

d.h.

$$L_x(\vartheta) \stackrel{!}{=} \max \iff \sum_{i=1}^n (x_i - \vartheta)^2 \stackrel{!}{=} \min.$$

Mit $m(x) := \frac{1}{n} \sum_{i=1}^n x_i$ ist

$$\sum_{i=1}^n (x_i - \vartheta)^2 = \sum_{i=1}^n (x_i - m(x))^2 + (m(x) - \vartheta)^2,$$

d.h. es ist $\hat{\vartheta}_{\text{ML}} = m(x)$, das empirische Mittel der Beobachtungen.

4. (Normales Modell, unbekannter Erwartungswert und unbekannte Varianz) n Beobachtungen seien u.i.v. $\sim \mathcal{N}_{\mu,v}$ mit unbekanntem $\mu \in \mathbb{R}$ und $v \in (0, \infty)$.

(Formalisierung: $\mathcal{X} = \mathbb{R}^n$, $\Theta = \{\vartheta = (\mu, v) : \mu \in \mathbb{R}, v > 0\}$, $P_{(\mu,v)} = \mathcal{N}_{\mu,v}^{\otimes n}$)

Wie in 3. ist

$$\log L_x((\mu, v)) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log v - \frac{1}{2v} \sum_{i=1}^n (x_i - \mu)^2,$$

nach obigem ist $\hat{\mu}_{\text{ML}} = \frac{1}{n} \sum_{i=1}^n x_i$ Maximierer bezüglich μ (für jeden Wert von v), weiter ist

$$\left. \frac{\partial}{\partial v} \log L_x((\mu, v)) \right|_{\mu=\hat{\mu}_{\text{ML}}} = -\frac{n}{2v} + \frac{1}{2v^2} \sum_{i=1}^n (x_i - \hat{\mu}_{\text{ML}})^2,$$

also $\frac{\partial}{\partial v} \log L_x((\hat{\mu}_{\text{ML}}, v)) = 0 \iff v = \hat{v}_{\text{ML}} = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{\mu}_{\text{ML}})^2$.

(Und man prüft: $\log L_x((\hat{\mu}_{\text{ML}}, v))$ ist wachsend für $v < \hat{v}_{\text{ML}}$, fallend für $v > \hat{v}_{\text{ML}}$.)

Beachte: Der ML-Schätzer für die unbekannte Varianz ist hier die (unkorrigierte) Stichprobenvarianz, also ist er nicht erwartungstreu (vgl. Beob. und Def. 6.5).

5. n Beobachtungen seien u.i.v. uniform auf $[0, \vartheta]$ (mit einem unbekanntem $\vartheta \in (0, \infty)$).

Es ist

$$\widehat{\vartheta}_{\text{ML}} = \max\{x_1, x_2, \dots, x_n\},$$

denn

$$L_{(x_1, \dots, x_n)}(\vartheta) = \begin{cases} \frac{1}{\vartheta^n}, & \text{falls } \vartheta \geq x_1, x_2, \dots, x_n, \\ 0, & \text{sonst.} \end{cases}$$

Bericht 6.8 (Cramér-Rao-Schranke und „beste“ Schätzer). Sei $(\mathcal{X}, \mathcal{F}, (P_\vartheta)_{\vartheta \in \Theta})$ ein statistisches Standardmodell, $\rho(x, \vartheta)$ die Likelihoodfunktion.

Ein erwartungstreuer Schätzer T für ein reelles Parametermerkmal $\tau(\vartheta)$ heißt *varianzminimierend* (auch „gleichmäßig bester Schätzer“, engl. UMVU (= uniformly minimum variance unbiased) estimator), falls für jeden anderen erwartungstreuen Schätzer \tilde{T} für τ gilt

$$\text{Var}_\vartheta[T] \leq \text{Var}_\vartheta[\tilde{T}] \quad \text{für alle } \vartheta \in \Theta.$$

(In diesem Sinne ist T optimal und beantwortet – so existent – auf diese Weise die Frage „Wie gut kann man $\tau(\vartheta)$ anhand der Beobachtungen überhaupt schätzen?“)

Ein einparametriges Standardmodell (d.h. $\Theta \subset \mathbb{R}$) heißt *regulär*, falls gilt:

- (i) $\Theta \subset \mathbb{R}$ ist ein offenes Intervall.
- (ii) Likelihood-Funktion $\rho(x, \vartheta)$ ist strikt positiv auf $\mathcal{X} \times \Theta$ und für jedes x ist $\vartheta \mapsto \rho(x, \vartheta)$ stetig diff'bar.
- (iii) $U_\vartheta(x) := \frac{d}{d\vartheta} \log \rho(x, \vartheta)$ erfüllt $I_\vartheta := \text{Var}_\vartheta[U_\vartheta] \in (0, \infty)$
(U_ϑ heißt die „Scorefunktion“ und I_ϑ heißt die *Fisher-Information*) und es gilt

$$\int_{\mathcal{X}} \frac{d}{d\vartheta} \rho(x, \vartheta) dx = \frac{d}{d\vartheta} \int_{\mathcal{X}} \rho(x, \vartheta) dx \quad (= 0).$$

Weiter heißt ein Schätzer T *regulär*, wenn für jedes $\vartheta \in \Theta$ gilt

$$\frac{d}{d\vartheta} \int_{\mathcal{X}} T(x) \rho(x, \vartheta) dx = \int_{\mathcal{X}} T(x) \frac{d}{d\vartheta} \rho(x, \vartheta) dx.$$

(Wenn \mathcal{X} diskret ist, so ist jeweils das Integral $\int_{\mathcal{X}} \dots dx$ durch die Summe $\sum_{x \in \mathcal{X}} \dots$ zu ersetzen.)

$U_{\vartheta}(x) := \frac{d}{d\vartheta} \log \rho(x, \vartheta)$ die Scorefunktion, $I_{\vartheta} := \text{Var}_{\vartheta}[U_{\vartheta}]$ die Fisher-Information.

Sei $\tau : \Theta \rightarrow \mathbb{R}$ ein stetig differenzierbares Parametermerkmal, T ein regulärer, erwartungstreuer Schätzer für τ in einem regulären Standardmodell. Dann gilt die Cramér-Rao-Schranke¹:

$$\text{Var}_{\vartheta}[T] \geq \frac{(\tau'(\vartheta))^2}{I(\vartheta)} \quad \forall \vartheta \in \Theta,$$

wobei Gleichheit genau dann gilt, wenn

$$T(x) - \tau(\vartheta) = \frac{\tau'(\vartheta)U_{\vartheta}(x)}{I(\vartheta)}.$$

¹nach Harald Cramér, 1983–1985 und Calyampudi Radhakrishna Rao, *1920