

# Kapitel 2

## Statistische Experimente, statistische Modelle

### 2.1 Definitionen

In diesem Kapitel führen wir einige Begriffe ein, und zwar in einer solchen Allgemeinheit, daß sie auch für stochastische Prozesse einsetzbar sind.

**Definition 2.1.** Es seien  $(\Omega, \mathcal{A})$  ein meßbarer Raum und  $\mathcal{P}$  eine Familie von Wahrscheinlichkeitsmaßen auf  $(\Omega, \mathcal{A})$ . Dann nennen wir  $(\Omega, \mathcal{A}, \mathcal{P})$  ein *statistisches Modell*. Weiterhin sei  $X$  eine Zufallsgröße auf  $(\Omega, \mathcal{A})$  mit Werten in einem meßbaren Raum  $(E, \mathcal{E})$ . Dann heißt  $(\Omega, \mathcal{A}, \mathcal{P}, X)$  ein *statistisches Experiment* und  $X$  wird als eine *mathematische Stichprobe* bezeichnet.

**Interpretation:** Ein zufälliges Experiment wird gemäß  $(\Omega, \mathcal{A}, \mathbb{P})$  mit einem bestimmten  $\mathbb{P} \in \mathcal{P}$ , das aber unbekannt ist, ausgeführt („wahres  $\mathbb{P}$ “). Dabei wird die Zufallsgröße  $X$  beobachtet, ihre Realisierungen  $x$  gehören zu  $E$ .  $x$  heißt *konkrete Stichprobe*,  $(E, \mathcal{E})$  nennt man *Stichprobenraum*.

Durch  $\mathbb{P}^X(B) = \mathbb{P}(X \in B)$ ,  $B \in \mathcal{E}$ , ist ein Wahrscheinlichkeitsmaß  $\mathbb{P}^X$  auf  $\mathcal{E}$  definiert, die Wahrscheinlichkeitsverteilung von  $X$  unter  $\mathbb{P}$  (*Stichprobenverteilung*).

Wir setzen  $\mathcal{P}^X := \{\mathbb{P}^X : \mathbb{P} \in \mathcal{P}\}$ .

$(E, \mathcal{E}, \mathcal{P}^X)$  ist ebenfalls ein statistisches Modell.

**Definition 2.2.**  $\mathcal{P}^X$  heißt die *zum statistischen Experiment  $(\Omega, \mathcal{A}, \mathcal{P}, X)$  gehörende Familie von Stichprobenverteilungen*

In dem genannten Experiment wird nur  $x$  beobachtet,  $(\Omega, \mathcal{A}, \mathcal{P})$  und  $X$  sind Hilfskonstruktionen.  $\mathcal{P}^X$  ist eine bekannte Familie, unter welcher wahren Verteilung  $\mathbb{P}^X \in \mathcal{P}$  die Stichprobe realisiert wurde, ist unbekannt.

Ziel ist es, aus der Kenntnis von  $x$  Schlüsse auf das „wahre“  $\mathbb{P}^X$  zu ziehen und die Güte dieser Rückschlüsse zu bewerten. Häufig indiziert man  $\mathcal{P}$  der besseren Handhabung wegen, das heißt, man setzt  $\mathcal{P} = (\mathbb{P}_\vartheta, \vartheta \in \Theta)$  und entsprechend  $\mathcal{P}^X = (\mathbb{P}_\vartheta^X, \vartheta \in \Theta)$ .  $\Theta$  heißt *Parametermenge* oder *Parameterraum*.

Gilt  $\Theta \subseteq \mathbb{R}^k$  für ein  $k \geq 1$ , so nennt man  $(\Omega, \mathcal{A}, \mathcal{P}, X)$  ein *parametrisches statistisches Modell* (*k-parametrisches Modell*). Läßt sich  $\Theta$  dagegen nicht durch endlich viele Parameter beschreiben, so spricht man von einem *nichtparametrischen Modell*.

Im Fall  $E = \mathbb{R}^n, \mathcal{E} = \mathcal{B}^n$  ist  $X$  ein zufälliger Vektor,  $x$  eine seiner Realisierungen. Wie bereits erwähnt, bezeichnet man in diesem Fall  $X$  als eine (mathematische) Stichprobe und  $x$  im Unterschied dazu als eine konkrete Stichprobe.

Im Fall, daß  $E$  ein Funktionenraum ist, bildet  $X = (X_t, t \in T)$  einen stochastischen Prozess und  $x$  eine Realisierung desselben. In diesem Fall ist der Begriff „Stichprobe“ weniger gebräuchlich. Man spricht von *Trajektorien* oder *Pfaden*. Wir werden in dieser Vorlesung in jedem der genannten Fälle  $X$  bzw.  $x$  als mathematische bzw. konkrete Stichprobe bezeichnen.

## 2.2 Klassische Statistische Experimente

Die Wahrscheinlichkeitsverteilungen  $\mathbb{P}_\vartheta^X, \vartheta \in \Theta$ , der Stichprobe  $X$  bilden eine Ausgangsbasis der mathematischen Statistik.

Auf ihrer Grundlage werden Schätzer für das unbekannte  $\vartheta$  oder Tests für Hypothesen über  $\vartheta$  konstruiert und untersucht. Für ihre Beschreibung bedient man sich der sogenannten Likelihoodfunktion, die wir vorerst in zwei Beispielen definieren.

Es sei  $(C, \mathcal{C})$  ein meßbarer Raum. Wir setzen  $E = C^n, \mathcal{E} = \mathcal{C}^{\otimes n}$  und  $X = (X_1, X_2, \dots, X_n)$ , wobei  $X_k : (\Omega, \mathcal{A}) \rightarrow (C, \mathcal{C})$  für jedes  $k = 1, \dots, n$  eine Zufallsgröße ist.

Es sei weiterhin  $\mathcal{P}$  eine Familie von Wahrscheinlichkeitsmaßen auf  $(\Omega, \mathcal{A})$ ,  $\mathcal{P} = \{\mathbb{P}_\vartheta, \vartheta \in \Theta\}$ . Unter folgenden Voraussetzungen

**Voraussetzung 1** Für jedes  $\mathbb{P}_\vartheta \in \mathcal{P}$  sind die Zufallsgrößen  $X_1, \dots, X_n$  identisch verteilt,

das heißt,

$$\mathbb{P}_\vartheta(X_k \in B) = \mathbb{P}_\vartheta(X_1 \in B), \quad B \in \mathcal{C}, \quad k = 1, \dots, n.$$

**Voraussetzung 2** Für jedes  $\mathbb{P}_\vartheta \in \mathcal{P}$  sind die  $X_1, \dots, X_n$  unter  $\mathbb{P}_\vartheta$  in ihrer Gesamtheit unabhängig, d.h.

$$\mathbb{P}_\vartheta(X \in B_1 \times \dots \times B_n) = \prod_{i=1}^n \mathbb{P}_\vartheta(X_i \in B_i).$$

gilt dann

$$\mathbb{P}_\vartheta^X(B_1 \times \dots \times B_n) = \prod_{i=1}^n \mathbb{P}_\vartheta(X_i \in B_i) = \prod_{i=1}^n \mathbb{P}_\vartheta^{X_i}(B_i) \quad (2.1)$$

Durch  $\mathbb{P}_\vartheta^X$  ist ein Wahrscheinlichkeitsmaß auf  $\mathcal{C}^{\otimes n}$  definiert, das wir ebenfalls mit  $\mathbb{P}_\vartheta^X$  bezeichnen.

**Beispiel 2.1 (diskreter Fall).** Es seien  $C = \{c_1, c_2, \dots\}$ ,  $\mathcal{C} = \mathcal{P}(C)$  die Potenzmenge von  $C$ ,  $E = C^n$  und  $\mathcal{E} = \mathcal{C}^{\otimes n}$ .  $X_1$  nehme nur Werte aus  $C$  an, d.h.  $X_1$  habe eine diskrete Verteilung mit

$$\mathbb{P}_\vartheta(X_1 = c_k) = p_k(\vartheta), \quad p_k(\vartheta) \geq 0, \quad k = 1, 2, \dots, \quad \sum_{k=1}^{\infty} p_k(\vartheta) = 1.$$

Dann hat auch  $X = (X_1, X_2, \dots, X_n)$  eine diskrete Verteilung und es gilt:

$$\mathbb{P}_\vartheta^X((c_{i_1}, \dots, c_{i_n})) = \prod_{k=1}^n p_{\vartheta}(c_{i_k}) = \mathbb{P}_\vartheta(X_1 = c_{i_1}, \dots, X_n = c_{i_n}) =: L_n(x, \vartheta), \quad x = (c_{i_1}, \dots, c_{i_n})$$

Diese Funktion  $L_n$  heißt *Likelihoodfunktion* des statistischen Experiments  $(\Omega, \mathcal{A}, \mathcal{P}, X)$ .

**Beispiel 2.2 (stetiger Fall).** Es seien  $C = \mathbb{R}$ ,  $E = \mathbb{R}^n$  und  $\mathcal{E} = \mathcal{B}(\mathbb{R}^n)$ .  $X_1$  besitze eine Dichte  $f_\vartheta(x)$ , d. h. es gelte

$$\mathbb{P}_\vartheta^X(D) = \int_D f_\vartheta(s) ds, \quad D \in \mathcal{B}.$$

Dann besitzt auch  $X = (X_1, \dots, X_n)$  eine Dichte  $f_\vartheta^X(x_1, \dots, x_n) = \prod_{i=1}^n f_\vartheta(x_i)$  und es gilt

$$\mathbb{P}_\vartheta^X(B_1 \times \dots \times B_n) = \int_{B_1} \cdots \int_{B_n} f_\vartheta(x_1) \cdots f_\vartheta(x_n) dx_1 \cdots dx_n.$$

In diesem Fall bezeichnet man  $L_n(x; \vartheta) := \prod_{k=1}^n f_\vartheta(x_k)$  als *Likelihoodfunktion* des statistischen Experiments  $(\Omega, \mathcal{A}, \mathcal{P}, X)$ .

**Interpretation:** Die Stichprobe  $X = (X_1, \dots, X_n)$  modelliert  $n$  voneinander unabhängige, unter gleichartigen Bedingungen ausgeführte zufällige Experimente, bei denen jeweils  $X_1, X_2, \dots, X_n$  beobachtet wird. Wir definieren  $Q_\vartheta := \mathbb{P}_\vartheta^{X_1}$ .

Man sagt,  $X$  sei eine *mathematische Stichprobe aus einer nach  $Q_\vartheta$  verteilten Grundgesamtheit*.

Jede ihrer Realisierungen  $x$  nennt man eine *konkrete Stichprobe aus einer nach  $Q_\vartheta$  verteilten Grundgesamtheit*.

Bezeichnung: Klassisches statistisches Experiment.

Wir kehren zurück zu allgemeinen statistischen Experimenten.

**Definition 2.3.** Es seien  $(\Omega, \mathcal{A}, \mathcal{P}, X)$  ein statistisches Experiment mit dem Stichprobenraum  $(E, \mathcal{E})$  und  $H$  eine meßbare Abbildung von  $(E, \mathcal{E})$  in einen meßbaren Raum  $(F, \mathcal{F})$ .  $H$  heißt eine *Stichprobenfunktion*. Insbesondere ist  $(\Omega, \mathcal{A}, \mathcal{P}, H \circ X)$  ein statistisches Experiment mit dem Stichprobenraum  $(F, \mathcal{F})$ .

Im allgemeinen geht bei dieser Abbildung  $H$  Information verloren (Datenreduktion), andererseits kann  $H(x)$  einfacher und übersichtlicher sein als  $x$ .

Setzt man in  $H$  die Zufallsgröße  $X$  ein, d. h.  $H(X) = H((X_1, \dots, X_n))$ , so erhält man eine neue Zufallsgröße, sie hat die Wahrscheinlichkeitsverteilung  $\mathbb{P}_\vartheta^H(B) = \mathbb{P}_\vartheta(H(X) \in B)$ ,  $B \in \mathcal{F}$ . Diese Wahrscheinlichkeitsverteilung wird unter anderem zum Studium der Eigenschaften der Stichprobe  $x$  in ihrem Verhältnis zum wahren Parameter  $\vartheta$  herangezogen. Die Berechnung der Verteilungen von Stichprobenfunktionen  $H(X)$  gehört zu den wesentlichen Aufgaben der mathematischen Statistik.

Anstelle von Stichprobenfunktion verwendet man auch einfach die Bezeichnung *Statistik*.

Wir nehmen an, daß  $\mathcal{P}$  die Form  $\mathcal{P} = \{\mathbb{P}_\vartheta, \vartheta \in \Theta\}$  mit irgendeiner Parametermenge  $\Theta$  hat. Eine Grundaufgabe der Statistik ist es, von der Beobachtung  $x$  auf den Parameter  $\vartheta$  bzw. eine Funktion  $\gamma(\vartheta)$  zu schließen. Häufig möchte man  $\vartheta$  bzw.  $\gamma(\vartheta)$  mit möglichst großer Genauigkeit bestimmen, man sagt „schätzen“.

**Definition 2.4.** Es seien  $\gamma$  eine Abbildung von  $\Theta$  in eine Menge  $\Gamma$ ,  $\mathcal{A}_\Gamma$  eine  $\sigma$ -Algebra von Teilmengen von  $\Gamma$  und  $g$  eine meßbare Abbildung von  $(E, \mathcal{E})$  in  $(\Gamma, \mathcal{A}_\Gamma)$ .

Dann heißt  $g$  eine *Schätzfunktion*,  $g(X)$  ein *Schätzer* und  $g(x)$  ein *Schätzwert* für  $\gamma(\vartheta)$ .

Jeder Schätzer ist also auch eine Stichprobenfunktion.

## 2.3 Ein Beispiel aus der klassischen Mathematischen Statistik

Es sei  $X_0$  eine reellwertige Zufallsgröße mit unbekannter Verteilungsfunktion  $F$ . Zu schätzen sei der Erwartungswert

$$E(X_0) = \int_{\mathbb{R}} x dF(x) =: m_F.$$

Da man über  $F$  keine Vorinformation hat, setzt man

$$\Theta = \{F : F \text{ Verteilungsfunktion auf } (\mathbb{R}, \mathcal{B}) \text{ mit } |m_F| < \infty\}$$

Die Problemstellung legt nahe  $\gamma(F) = m_F$  zu setzen.

Vorausgesetzt werde ferner, daß eine  $n$ -elementige Stichprobe  $x = (x_1, x_2, \dots, x_n)$  vorliegt, die aus  $n$  voneinander unabhängigen unter gleichartigen Bedingungen durchgeführten Versuchen gewonnen wurden. Dabei wird beim  $k$ -ten Versuch,  $k = 1, \dots, n$  registriert, welchen Wert die Zufallsgröße  $X_0$  annimmt. Intuitiv verwenden wir als Schätzwert  $g(x)$  für  $\gamma(F) = m_F$  den Wert

$$g(x) = \bar{x}_n = \frac{1}{n} \sum_{k=1}^n x_k.$$

Die eben getroffenen Voraussetzungen legen es nahe, eine mathematische Stichprobe  $X = (X_1, X_2, \dots, X_n)$  zu betrachten, die aus  $n$  voneinander unabhängigen und identisch wie  $X_0$  verteilten Zufallsgrößen besteht.

Als Schätzer für  $m_F$  ergibt sich

$$g(X) = \bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k.$$

Zur Illustration typischer Aussagen der Mathematischen Statistik stellen wir eine Reihe von Eigenschaften dieses Schätzers zusammen.

**Aussage:** Es gelten folgende Eigenschaften

a)  $E_F(\bar{X}_n) = m_F$ , man sagt,  $\bar{X}_n$  ist ein *erwartungstreuer Schätzer*

b)  $D_F^2 \bar{X}_n = E_F((\bar{X}_n - m_F)^2) = \frac{D_F^2 X_0}{n}$ , falls  $\sigma^2 := D_F^2 X_0 < \infty$ .

Insbesondere gilt

$$\mathbb{P}_F(|\bar{X}_n - m_F| \geq a) \leq \frac{\sigma_F^2}{na^2} \quad a > 0, \quad n \geq 1$$

(Schwaches Gesetz der großen Zahlen). Man sagt, daß der Schätzer  $\bar{X}_n$  *konsistent* ist.

c)  $\lim_{n \rightarrow \infty} \bar{X}_n = m_F$   $\mathbb{P}_F$ -fast sicher (Starkes Gesetz der großen Zahlen)

d) Angenommen,

$$I_F := \{t \in \mathbb{R} : E_F(e^{tX}) < \infty\}$$

ist eine Umgebung von 0.  $h_F$  sei die Cramertransformierte von  $F$  (siehe Übungen),  $\epsilon$  sei irgendeine positive Zahl. Dann ist

$$P_F(\bar{X}_n \geq m_F + \epsilon) \leq \exp\{-nh_F(m_F + \epsilon)\} \text{ und } P_F(\bar{X}_n \leq m_F - \epsilon) \leq \exp\{-nh_F(m_F - \epsilon)\},$$

das bedeutet insbesondere, daß  $P_F(|\bar{X}_n - m_F| \geq \epsilon)$  exponentiell schnell gegen 0 konvergiert.

e) Der Zentrale Grenzwertsatz besagt, daß

$$P_F(|\bar{X}_n - m_F| > \epsilon) = P_F\left(|\bar{X}_n - m_F| \frac{\sqrt{n}}{\sigma} > \epsilon \frac{\sqrt{n}}{\sigma}\right) \approx 2\left(1 - \Phi\left(\epsilon \frac{\sqrt{n}}{\sigma}\right)\right).$$

Beide Methoden d) und e) führen zur Abschätzung der Genauigkeit der Approximation von  $m_F$  durch  $\bar{X}_n$ .

Die erste Methode liefert:

Die Wahrscheinlichkeit, daß man sich irrt, wenn man sagt,  $m_F$  befinde sich in  $(-\infty, \bar{X}_n + \epsilon)$  und in  $(\bar{X}_n - \epsilon, \infty)$  konvergiert mit wachsendem  $n$  exponentiell schnell gegen Null.

Die zweite Methode liefert:

Es wird ein  $\alpha \in (0, 1)$  fixiert und man erhält für große  $n$  Vertrauensintervalle

$$\left(-\infty, \bar{X}_n + \frac{\sigma_F}{\sqrt{n}} q_{1-\alpha}\right], \left[\bar{X}_n - \frac{\sigma_F}{\sqrt{n}} q_{1-\alpha}, \infty\right), \left[\bar{X}_n - \frac{\sigma_F}{\sqrt{n}} q_{1-\frac{\alpha}{2}}, \bar{X}_n + \frac{\sigma_F}{\sqrt{n}} q_{1-\frac{\alpha}{2}}\right)$$

des Niveaus  $1 - \alpha$ , von denen man sagen kann, daß  $m_F$  mit einer Irrtumswahrscheinlichkeit nahe bei  $\alpha$  in denen liegt.

## 2.4 Empirische Schätzer

*Klassischer Fall:*

Es sei  $(\Omega, \mathcal{A}, \mathcal{P}, X)$  ein statistisches Experiment mit dem Stichprobenraum  $E = \mathbb{R}^n$ ,  $\mathcal{E} = \mathcal{B}^n$  und  $X = (X_1, X_2, \dots, X_n)$  bestehe aus reellwertigen, unabhängigen und identisch verteilten Zufallsgrößen  $X_k$ ,  $k = 1, \dots, n$  mit Verteilungsfunktion  $F$ . Die Familie  $\mathcal{P}$  sei parametrisiert:  $\mathcal{P} = (\mathbb{P}_\vartheta, \vartheta \in \Theta)$ ,  $\Theta \subseteq \mathbb{R}^k$ .

### Empirische Verteilungsfunktion

Es seien

$$\hat{F}_n(x) = \frac{1}{n} \sum_{k=1}^n \mathbf{1}_{\{X_k \leq x\}}, \quad m_l(F) = \int_{\mathbb{R}} x^l dF(x), \quad l \in \mathbb{N}$$

Diese Verteilungsfunktion  $\hat{F}_n(\cdot)$  gehört zur gleichmäßigen Verteilung auf  $(X_1, X_2, \dots, X_n)$ . Sie hat  $m_l(\hat{F}_n) = \frac{1}{n} \sum_{k=1}^n X_k^l$  als  $l$ -tes Moment.

**Aussage 2.1 (Hauptsatz der mathematischen Statistik).** *Es sei  $(X_n, n \geq 1)$  eine Folge unabhängiger, identisch nach  $F$  verteilter Zufallsgrößen mit Werten in  $\mathbb{R}^k$ .*

*Dann konvergiert die Folge  $(\hat{F}_n(\cdot, \omega))$  schwach gegen  $F(\cdot)$  (d.h.  $\hat{F}_n(f) \rightarrow F(f)$ ,  $\forall f \in \mathbb{C}_b$ ). Ist  $k = 1$ , so erfolgt die Konvergenz  $\mathbb{P}$ -f.s. gleichmäßig, d.h.*

$$\sup_{x \in \mathbb{R}} |\hat{F}_n(x, \omega) - F(x)| \rightarrow 0 \quad \text{für } \mathbb{P}\text{-f.a. } \omega \in \Omega.$$

*Beweis:*

s. Dacunha-Castelle, Duflo I, 4.4

□

### Eine Konstruktionsmethode für Schätzer: Empirische Schätzer

Ist  $\gamma(F)$  die zu schätzende Größe, so verwendet man  $\gamma(\hat{F}_n)$  als Schätzer (sofern  $\gamma$  auf den Treppenfunktionen definiert ist, bzw. Sinn macht).

a) MOMENTENMETHODE

Zu schätzen sind der Erwartungswert  $\mu = m_1(F) = \int_{\mathbb{R}} x dF(x)$  und die Streuung  $\sigma_F^2 = m_2(F) - (m_1(F))^2$ .

Wir wenden die Abbildungen  $F \rightarrow m_1(F)$  und  $F \rightarrow \sigma_F^2$  auf  $\hat{F}_n$  an und erhalten die „Momentenschätzer“

$$\hat{\mu} = m_1(\hat{F}_n) = \frac{1}{n} \sum_{k=1}^n X_k = \bar{X}_n, \quad (\text{erwartungstreu})$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{k=1}^n X_k^2 - \left( \frac{1}{n} \sum_{k=1}^n X_k \right)^2 = \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X}_n)^2.$$

Allgemeiner: Man berechne die Momente  $m_l(F_\vartheta) = \mathbb{E}_\vartheta(X_1^l)$ , ersetze  $m_l(F_\vartheta)$  durch  $m_l(\hat{F}_n)$  und löse die Gleichungen nach  $\vartheta$  (bzw. nach  $\gamma(\vartheta)$ ) auf. Im Ergebnis erhält man einen Schätzer  $\hat{\vartheta}_n$  bzw.  $\hat{\gamma}_n$  für  $\vartheta$  bzw.  $\gamma(\vartheta)$ , einen sogenannten Momentenschätzer.

**Beispiel 2.3.** Es sei  $F_\lambda$  die Verteilungsfunktion der Exponentialverteilung mit Parameter  $\lambda > 0$ .

In diesem Fall gilt:

$$m_1(F) = \lambda \int_0^\infty x e^{-\lambda x} dx = \frac{1}{\lambda}, \quad \bar{X}_n = \widehat{\left( \frac{1}{\lambda} \right)}, \quad \text{wobei } \gamma(F_\lambda) = \frac{1}{\lambda}.$$

$\bar{X}_n$  ist ein erwartungstreuer Schätzer für  $\gamma(\lambda) = \frac{1}{\lambda}$ . Ein möglicher Schätzer für  $\lambda$  wäre zum Beispiel  $\frac{1}{\bar{X}_n}$ . Es wird sich aber herausstellen, daß dieser Schätzer nicht erwartungstreu ist.

Wir kehren zur Schätzung von  $\sigma_F^2$  zurück:

$$\hat{\sigma}_F^2 := \frac{1}{n} \sum_{k=1}^n (X_k - \bar{X}_n)^2 \quad \text{ist die Momentenschätzung für } \sigma_F^2.$$

Es gilt:

$$\begin{aligned} E_F(\hat{\sigma}_F^2) &= \frac{1}{n} E_F \left( \left( \sum_{k=1}^n X_k^2 \right) - n \bar{X}_n^2 \right) \\ &= \frac{1}{n} \sum_{k=1}^n E_F X_k^2 - E_F \bar{X}_n^2 \\ &= \frac{1}{n} ((\sigma_F^2 + \mu_F^2) n) - \frac{\sigma_F^2}{n} - \mu^2 \\ &= \sigma_F^2 + \mu_F^2 - \frac{\sigma_F^2}{n} - \mu^2 \\ &= \sigma_F^2 \left( \frac{n-1}{n} \right) \end{aligned}$$

Also ist  $\hat{\sigma}_F^2$  nicht erwartungstreu, man unterschätzt  $\sigma_F^2$  regelmäßig. Aber

$$S_n^2 = \frac{1}{n-1} \hat{\sigma}_F^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X}_n)^2$$

ist eine erwartungstreue Schätzung für  $\sigma_F^2$ .

Für das Beispiel 2.3 gilt dann:

$S_n^2$  ist eine erwartungstreue Schätzung für  $\frac{1}{\lambda^2}$ ,  $\sqrt{S_n^2}$  ist eine Schätzung für  $\frac{1}{\lambda}$ .

**Beispiel 2.4.** Es sei  $X = (X_1, X_2, \dots, X_n)$  eine klassische mathematische Stichprobe aus einer Grundgesamtheit, die eine gemischte Poissonverteilung besitzt:

$$\mathbb{P}_\vartheta(X_1 = k) = a \cdot \frac{\lambda_1^k}{k!} e^{-\lambda_1} + (1-a) \frac{\lambda_2^k}{k!} e^{-\lambda_2}, \quad k \geq 0$$

mit  $\vartheta = (a, \lambda_1, \lambda_2)$ ,  $a \in (0, 1)$ ,  $\lambda_1, \lambda_2 > 0$ . Die entsprechende Verteilungsfunktion werde mit  $F_\vartheta$  bezeichnet.

Für die momenterzeugende Funktion

$$\varphi_\vartheta(s) := \mathbb{E}_\vartheta(s^{X_1}) = \sum_{k \geq 0} \mathbb{P}_\vartheta(X_1 = k) s^k = a e^{\lambda_1(s-1)} + (1-a) e^{\lambda_2(s-1)}, \quad s \in [0, 1]$$

gilt:

$$T_1(F_\vartheta) := \varphi'_\vartheta(1) = \mathbb{E}_\vartheta X_1 = a\lambda_1 + (1-a)\lambda_2$$

$$T_2(F_\vartheta) := \varphi''_\vartheta(1) = \mathbb{E}_\vartheta X(X-1) = a\lambda_1^2 + (1-a)\lambda_2^2$$

$$T_3(F_\vartheta) := \varphi'''_\vartheta(1) = \mathbb{E}_\vartheta X(X-1)(X-2) = a\lambda_1^3 + (1-a)\lambda_2^3$$

Wir definieren die entsprechenden empirischen Momente

$$T_1(\hat{F}_n) = \frac{1}{n} \sum_{k=1}^n X_k, \quad T_2(\hat{F}_n) = \frac{1}{n} \sum_{k=1}^n X_k(X_k - 1),$$

$$T_3(\hat{F}_n) = \frac{1}{n} \sum_{k=1}^n X_k(X_k - 1)(X_k - 2).$$

Ist  $x = (x_1, x_2, \dots, x_n)$  eine konkrete Stichprobe aus der nach  $F_\vartheta$  verteilten Grundgesamtheit, so erhält man folgende Gleichungen, aus denen sich die empirischen Schätzer

$\hat{a}, \hat{\lambda}_1, \hat{\lambda}_2$  für  $\vartheta = (a, \lambda_1, \lambda_2)$  berechnen lassen:

$$\begin{aligned}\hat{a}\hat{\lambda}_1 + (1 - \hat{a})\hat{\lambda}_2 &= T_1(\hat{F}_n) = \frac{1}{n} \sum_{k=1}^n x_k \\ \hat{a}\hat{\lambda}_1^2 + (1 - \hat{a})\hat{\lambda}_2^2 &= T_2(\hat{F}_n) = \frac{1}{n} \sum_{k=1}^n x_k(x_k - 1) \\ \hat{a}\hat{\lambda}_1^3 + (1 - \hat{a})\hat{\lambda}_2^3 &= T_3(\hat{F}_n) = \frac{1}{n} \sum_{k=1}^n x_k(x_k - 1)(x_k - 2).\end{aligned}$$

b) SCHÄTZUNG DER SCHRANKEN DES TRÄGERS VON  $F$ :

$$\begin{aligned}m &= \sup\{a \in \mathbb{R} : F(a) = 0\}, & M &= \inf\{a \in \mathbb{R} : F(a) = 1\} \\ \hat{m}_n &= \min\{X_k, k = 1, \dots, n\}, & \hat{M}_n &= \max\{X_k, k = 1, \dots, n\}\end{aligned}$$

## 2.5 Eigenschaften von Schätzern

Es sei  $(\Omega, \mathcal{A}, \mathcal{P}, X)$  ein statistisches Experiment mit dem Stichprobenraum  $(E, \mathcal{E})$  und es sei  $\mathcal{P} = (\mathbb{P}_\vartheta, \vartheta \in \Theta)$ . Weiterhin sei  $\gamma$  wie oben eine meßbare Funktion von  $\Theta$  in  $\Gamma$  und  $g(X)$  ein Schätzer für  $\gamma(\vartheta)$ .

Der Einfachheit halber nehmen wir an,  $\Gamma \subseteq \mathbb{R}$ . Zur Beurteilung der Güte des Schätzers  $g(X)$  definieren wir die *Risikofunktion*

$$R(g, \vartheta) := \mathbb{E}_\vartheta (g(X) - \gamma(\vartheta))^2 \quad \vartheta \in \Theta$$

$R(g, \vartheta)$  ist also die mittlere quadratische Abweichung des Schätzers  $g(X)$  von dem zu schätzenden Wert  $g(\vartheta)$ , wenn  $\mathbb{P}_\vartheta$  die zugrundeliegende Wahrscheinlichkeitsverteilung ist.

Man wähle die Schätzfunktion  $g(\cdot)$  so, daß  $R(g, \vartheta)$  möglichst minimal wird.

Unter der Voraussetzung, daß  $R(g, \vartheta) < \infty, \quad \forall \vartheta \in \Theta$  definiere:

**Definition 2.5.** Ein Schätzer  $h(X)$  für die Funktion  $\gamma(\vartheta)$  heißt *besser als*  $g(X)$ , falls gilt:

$$R(h, \vartheta) \leq R(g, \vartheta) \text{ für alle } \vartheta \in \Theta \text{ und } R(h, \vartheta) < R(g, \vartheta) \text{ für mindestens ein } \vartheta \in \Theta.$$

Wenn es zu einem gegebenen Schätzer  $g(X)$  für  $\gamma(\vartheta)$  einen besseren Schätzer  $h(X)$  für  $\gamma(\vartheta)$  gibt, so nennt man  $g(X)$  *nicht zulässig* (als Schätzer für  $\gamma(\vartheta)$ ).

$g(X)$  heißt *zulässiger Schätzer* für  $\gamma(\vartheta)$ , falls es keinen besseren Schätzer für  $\gamma(\vartheta)$  gibt.

Es ist vernünftig, sich auf zulässige Schätzer zu beschränken.

**Definition 2.6.** Ein Schätzer  $g^*(X)$  für  $\gamma(\vartheta)$  heißt *optimal*, falls

$$R(g^*, \vartheta) = \inf_g R(g, \vartheta) \quad \text{für alle } \vartheta \in \Theta,$$

wobei das Infimum über alle (zulässigen) Schätzer  $g(X)$  für  $\gamma(\vartheta)$  gebildet wird.

*Im allgemeinen gibt es keinen optimalen Schätzer für  $\gamma(\vartheta)$ !*

**Begründung:** Für jedes fest gewählte  $\vartheta_0 \in \Theta$  ist  $\inf_g R(g, \vartheta_0) = 0$ , da der Schätzer  $g(X) \equiv \gamma(\vartheta_0)$  unter allen konkurrierenden Schätzern vorkommt.

Dieser Schätzer ist sehr gut, wenn  $\vartheta = \vartheta_0$  der wahre Parameter ist, aber für andere  $\vartheta$  allerdings nicht.

Wir verfolgen unser Ziel, eine vernünftige Schätzfunktion  $g$  zu finden, die das mittlere quadratische Risiko möglichst klein hält, durch folgende Überlegungen:

Es gilt

$$\begin{aligned} R(g, \vartheta) &= \mathbb{E}_\vartheta \left( g(X) - \mathbb{E}_\vartheta (g(X)) \right)^2 + \mathbb{E}_\vartheta \left( \mathbb{E}_\vartheta (g(X)) - \gamma(\vartheta) \right)^2 \\ &=: D_\vartheta^2 g(X) + b_{g, \gamma}(\vartheta), \quad \vartheta \in \Theta \end{aligned} \quad (2.2)$$

Risikofunktion = zufallsbedingte Streuung + Verzerrung<sup>2</sup>.

Die Größe  $b_{g, \gamma}(\vartheta)$  heißt *Verzerrung* oder *Bias* des Schätzers  $g(X)$  bezüglich  $\gamma(\vartheta)$ .

Wenn man das Risiko  $R(\cdot)$  für alle  $\vartheta \in \Theta$  minimieren will, ist es also vernünftig, unter den erwartungstreuen (unverzerrten) Schätzern, d.h. Schätzern mit  $\mathbb{E}_\vartheta (g(X)) = \gamma(\vartheta)$ ,  $\vartheta \in \Theta$  zu suchen.

Wir beschränken uns deshalb darauf, unverzerrte Schätzer mit möglichst kleiner Streuung zu suchen.

Angenommen  $H(X)$  ist eine Stichprobenfunktion und  $g(X)$  ist ein Schätzer für  $\gamma(\vartheta)$ . Eine ähnliche Rechnung wie in (2.2) führt auf

$$R(g, \vartheta) = \mathbb{E}_\vartheta \left( g(X) - \mathbb{E}_\vartheta (g(X) | H(X)) \right)^2 + \mathbb{E}_\vartheta \left( \mathbb{E}_\vartheta (g(X) | H(X)) - \gamma(\vartheta) \right)^2$$

**Definition 2.7.** Die Stichprobenfunktion  $H(X)$  heißt eine *suffiziente* oder *erschöpfende* Statistik, falls die Wahrscheinlichkeitsverteilung  $\mathbb{P}_\vartheta^X(\cdot | H(X))$  nicht von  $\vartheta$  abhängt.

Wir kommen auf diesen Begriff später ausführlich zurück.

Ist  $H(X)$  eine suffiziente Statistik, so ist  $g_1(X) := \mathbb{E}_\vartheta(g(X) \mid H(X))$  ein neuer Schätzer für  $\gamma(\vartheta)$  mit kleinerem Risiko ( $g_1(X)$  hängt nicht von  $\vartheta$  ab):

$$R(g_1, \vartheta) = \mathbb{E}_\vartheta (g_1(X) - \gamma(\vartheta))^2 \leq R(g, \vartheta), \quad \vartheta \in \Theta.$$

Da  $g_1(X)$  eine Funktion von  $H(X)$  ist, genügt es also, als Schätzer für  $\gamma(\vartheta)$  lediglich Funktionen suffizienter Statistiken in Betracht zu ziehen.

### Beispiel einer suffizienten Statistik

Ein zufälliger Versuch möge nur die Ausgänge 0 und 1 besitzen, wobei 1 mit der unbekanntem Wahrscheinlichkeit  $\vartheta \in (0, 1) =: \Theta$  als Ergebnis auftritt. Zur Schätzung von  $\vartheta$  verschafft man sich eine Stichprobe  $(i_1, i_2, \dots, i_n)$  aus  $n$  unabhängig und unter gleichartigen Bedingungen durchgeführten Versuchen.

Zur mathematischen Modellierung dieses Sachverhalts führen wir ein:

$$\begin{aligned} \Omega &= \{\omega = (i_1, i_2, \dots, i_n) : i_k \in \{0, 1\}, k = 1, 2, \dots, n\}, \quad \mathcal{A} = \wp(\Omega), \\ X &= (X_1, X_2, \dots, X_n) \text{ mit } X_k(\omega) = i_k, \quad k = 1, \dots, n \text{ für } \omega = (i_1, i_2, \dots, i_n) \in \Omega, \\ S_n &= \sum_{k=1}^n X_k \text{ und } \mathbb{P}_\vartheta(\{\omega\}) = \vartheta^{\sum_{k=1}^n i_k} (1 - \vartheta)^{n - \sum_{k=1}^n i_k}, \quad \omega \in \Omega. \end{aligned}$$

Bezüglich jedem  $\mathbb{P}_\vartheta$  sind  $X_1, X_2, \dots, X_n$  unabhängige und identisch verteilte Zufallsgrößen mit  $\mathbb{P}_\vartheta(X_k = i) = \vartheta^i (1 - \vartheta)^{1-i}$ ,  $i \in \{0, 1\}$ .

**Aussage 2.2.**  $S_n = \sum_{k=1}^n X_k$  ist eine suffiziente Statistik.

*Beweis:*

Es gilt:

$$\mathbb{P}_\vartheta(\{\omega\} \mid S_n = m) = \begin{cases} \frac{1}{\binom{n}{m}}, & \text{falls } \omega = (i_1, i_2, \dots, i_n) \text{ mit } \sum_{k=1}^n i_k = m \\ 0, & \text{falls } \omega = (i_1, i_2, \dots, i_n) \text{ mit } \sum_{k=1}^n i_k \neq m \end{cases}$$

□

Zur Schätzung von  $\vartheta$  beschränken wir uns also auf Funktionen der Form  $g(S_n)$ .

Soll  $g(S_n)$  erwartungstreu sein, so erhalten wir aus der Forderung

$$\mathbb{E}_\vartheta g(S_n) = \vartheta, \quad \vartheta \in [0, 1]$$

die Gleichungen

$$\sum_{m=0}^n g(m) \binom{n}{m} \vartheta^m (1 - \vartheta)^{n-m} = \vartheta, \quad \vartheta \in [0, 1],$$

woraus sich durch Koeffizientenvergleich

$$g(m) = \frac{m}{n}, \quad m = 0, 1, \dots, n, \quad \text{d.h. } \hat{\vartheta}_n = \frac{S_n}{n}$$

ergibt. Wir werden später zeigen, daß diese Schätzung die minimale Streuung unter allen erwartungstreuen Schätzungen für  $\vartheta$  hat.

Es gilt:

$$\mathbb{P}_\vartheta(\{\omega\}) = \sum_{m=0}^n \mathbb{P}(\{\omega\} \mid S_n = m) \mathbb{P}_\vartheta(S_n = m)$$

Die Abhängigkeit des Maßes  $\mathbb{P}_\vartheta$  von  $\vartheta$  auf  $\mathcal{A}$  wird also allein durch die Abhängigkeit von  $\mathbb{P}_\vartheta^{S_n}$  von  $\vartheta$  vermittelt.