

# Kapitel 3

## Likelihoodschätzer im klassischen 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, bezüglich jedem  $\mathbb{P} \in \mathcal{P}$  unabhängigen und identisch verteilten Zufallsgrößen  $X_k$ ,  $k = 1, \dots, n$ . Die Familie  $\mathcal{P}$  sei parametrisiert:

$\mathcal{P} = (\mathbb{P}_\vartheta, \vartheta \in \Theta)$ ,  $\Theta \subseteq \mathbb{R}^k$ , und

$F_\vartheta(x) := \mathbb{P}_\vartheta(X_1 \leq x)$ ,  $x \in \mathbb{R}$ ,  $\vartheta \in \Theta$  bezeichne die Verteilungsfunktion von  $X_1$  bezüglich  $\mathbb{P}_\vartheta$ .

Dann hat  $X$  die Verteilungsfunktion

$$F_\vartheta^X(x_1, \dots, x_n) = \prod_{m=1}^n F_\vartheta(x_m) = \mathbb{P}_\vartheta(X \in (-\infty, x_1] \times \dots \times (-\infty, x_n]).$$

Besitzt  $F_\vartheta$  eine Dichte  $f_\vartheta$ , so hat  $X$  die Dichte

$$f_\vartheta^X(x_1, \dots, x_n) = \prod_{m=1}^n f_\vartheta(x_m).$$

Das bedeutet  $\mathbb{P}_\vartheta(X \in B) = \int_B f_\vartheta^X dx$  für alle Borelmengen  $B \in \mathcal{B}$ .

Ist  $X_1$  diskret verteilt mit  $\mathbb{P}_\vartheta(X_1 = a_m) = p_m(\vartheta)$ , so ist auch  $X$  diskret verteilt und es gilt

$$\mathbb{P}_\vartheta\left(X = (a_{m_1}, \dots, a_{m_n})\right) = \prod_{r=1}^n p_{m_r}(\vartheta)$$

In beiden Fällen nennt man (bei festgehaltener Stichprobe  $x = (x_1, \dots, x_n)$  bzw.  $x = (a_{m_1}, \dots, a_{m_n})$ )

$$L_n(\vartheta; x_1, \dots, x_n) = \prod_{m=1}^n f_\vartheta(x_m) \quad \text{bzw.} \quad = \prod_{r=1}^n p_{m_r}(\vartheta), \quad \vartheta \in \Theta,$$

die *Likelihood-Funktion* des statistischen Experiments.

**Maximum-Likelihood-Schätzer (ML-Schätzer)**

Es sei  $x$  eine (konkrete) Stichprobe aus  $E = \mathbb{R}^n$ ,  $x \in \text{supp}(X)$ .

**Definition 3.1.** Jeder Wert  $\hat{\vartheta}(x)$  aus  $\Theta$ , der die Likelihoodfunktion  $L_n(\cdot; x)$  bei gegebenem  $x$  maximiert, heißt ein *Maximum-Likelihood-Schätzwert* für  $\vartheta$  auf der Basis der Stichprobe  $x$ :

$$\hat{\vartheta}_n(x) := \arg \max_{\vartheta \in \Theta} L_n(\vartheta; x) = \arg \max_{\vartheta \in \Theta} \log L_n(\vartheta; x)$$

Offenbar ist  $\hat{\vartheta}_n(\cdot)$  eine Stichprobenfunktion. Setzt man die mathematische Stichprobe  $X$  ein, so erhält man einen sogenannten *Maximum-Likelihood-Schätzer* (kurz: ML-Schätzer)  $\hat{\vartheta}_n(X)$ .

*R.A. Fisher: Maximum-Likelihood-Prinzip*

„Finde diejenigen Voraussetzungen, die das Beobachtete mit großer Wahrscheinlichkeit nach sich ziehen und fasse Zutrauen, daß diese Voraussetzungen die wirksamen sind.“

**Bemerkung:** Maximum-Likelihood-Schätzer sind häufig einfach auszurechnen, haben vielfach gute Eigenschaften, existieren aber nicht immer oder sind nicht eindeutig. ML-Prinzip ist ein sehr allgemeines Prinzip, kann auch bei stochastischen Prozessen angewendet werden.

**Maximum-Likelihood-Gleichungen**

Unter der Voraussetzung, daß  $L_n(\vartheta; x_1, \dots, x_n)$  für jedes  $(x_1, \dots, x_n) \in \text{supp}(X)$  bezüglich  $\vartheta$  differenzierbar ist, sind

$$\frac{\partial}{\partial \vartheta_r} L_n(\hat{\vartheta}_n; x_1, \dots, x_n) = 0 \quad r = 1, 2, \dots, k \quad (\text{„ML-Gleichungen“}) \quad (3.1)$$

notwendige Bedingungen für  $\hat{\vartheta}_n$ , ein ML-Schätzer zu sein, sofern das Maximum von  $L_n$  im Inneren von  $\Theta$  angenommen wird.

Anstelle  $L_n$  führt man

$$l_n(\vartheta; x_1, \dots, x_n) = \log L_n(\vartheta; x_1, \dots, x_n) \quad \text{ein.} \quad (\text{„Loglikelihoodfunktion“})$$

Äquivalent zu (3.1) ist

$$\frac{\partial}{\partial \vartheta_r} l_n(\hat{\vartheta}_n; x_1, \dots, x_n) = 0 \quad r = 1, 2, \dots, k. \quad (3.2)$$

Die Funktion

$$\dot{l}_n(\vartheta; x_1, \dots, x_n) := \left( \frac{\partial}{\partial \vartheta_r} l_n(\vartheta; x_1, \dots, x_n), \quad r = 1, 2, \dots, k \right), \quad \vartheta \in \Theta$$

nennt man *Scorefunktion* des statistischen Experiments  $(\Omega, \mathcal{A}, \mathcal{P}, X)$ .

Es gilt

$$\begin{aligned} l_n(\vartheta; x_1, \dots, x_n) &= \text{grad } l_n(\vartheta; x_1, \dots, x_n) \quad \text{und} \\ \mathbb{E}_\vartheta \left( \dot{l}_n(\vartheta; X_1, \dots, X_n) \right) &= \mathbb{E}_\vartheta \left( \frac{\dot{L}_n}{L_n} \right) = \int \cdots \int_{\mathbb{R}^n} \dot{L}_n(\vartheta; x_1, \dots, x_n) dx_1 \cdots dx_n \\ &= \text{grad} \int \cdots \int_{\mathbb{R}^n} L_n dx_1 \cdots dx_n \\ &= 0 \end{aligned}$$

(Hier haben wir vorausgesetzt, daß Differentiation nach  $\vartheta$  und Integration bezüglich  $x$  vertauschbar sind.)

**Bemerkung:**

$$l_n(\vartheta; X_1, \dots, X_n) = \sum_{m=1}^n \log f_\vartheta(X_m)$$

ist eine Summe unabhängiger und identisch verteilter Zufallsgrößen.

$$\dot{l}_n(\vartheta; X_1, \dots, X_n) = \text{grad}_\vartheta l_n(\vartheta; X_1, \dots, X_n)$$

ist eine zentrierte Summe unabhängiger identisch verteilter Zufallsvektoren.

Für jedes feste  $\vartheta$  sind  $L_n(\vartheta; X_1, \dots, X_n)$ ,  $l_n(\vartheta; X_1, \dots, X_n)$  und  $\dot{l}_n(\vartheta; X_1, \dots, X_n)$  Stichprobenfunktionen.

**Definition 3.2.** Ist  $E = \{x \in \mathbb{R} \mid f_\vartheta(x) > 0\}$  (bzw.  $E = \{a \in \mathbb{R} \mid \mathbb{P}_\vartheta(X = a) > 0\}$ ) unabhängig von  $\vartheta$ , so nennt man für  $\vartheta, \alpha \in \Theta$  und  $x \in E$  den Quotienten

$$\frac{L_n(\alpha; x)}{L_n(\vartheta; x)} \quad \text{den Likelihoodquotienten.}$$

Ist  $\log \frac{f_\alpha}{f_\vartheta}$  bezüglich  $F_\vartheta$  integrierbar, so gilt

$$\frac{1}{n} \log \frac{L_n(\alpha; X_1, \dots, X_n)}{L_n(\vartheta; X_1, \dots, X_n)} \xrightarrow{\mathbb{P}_\vartheta\text{-f.s.}} \int \left[ \log \frac{f_\alpha}{f_\vartheta} \right] f_\vartheta dx =: -K(F_\vartheta, F_\alpha)$$

$K(F_\vartheta, F_\alpha)$  heißt *Kullback-Information von  $F_\vartheta$  bezüglich  $F_\alpha$* .

**Lemma 3.3.** *Es gilt:*

$$K(F_\vartheta, F_\alpha) \geq 0$$

$$K(F_\vartheta, F_\alpha) = 0 \iff F_\vartheta = F_\alpha$$

Im Fall, daß  $X_1$  eine diskrete Verteilung besitzt, gilt

$$K(F_\vartheta, F_\alpha) = - \sum_m \left[ \log \frac{p_m(\alpha)}{p_m(\vartheta)} \right] p_m(\vartheta).$$

*Beweis:* (nur für den Dichtefall)

Die Funktion  $h(x) = x \log x + 1 - x$  ist für  $x > 0$  und  $x \neq 1$  positiv und nur für  $x = 1$  gleich Null. Folglich gilt:

$$\int \left( \frac{f_\alpha}{f_\vartheta} \log \frac{f_\alpha}{f_\vartheta} + 1 - \frac{f_\alpha}{f_\vartheta} \right) f_\vartheta dx \geq 0$$

und  $K(F_\vartheta, F_\alpha) = 0$  impliziert  $f_\alpha = f_\vartheta$ .

Also gilt für  $\alpha \neq \vartheta$  die Beziehung  $-K(F_\vartheta, F_\alpha) < 0$  und somit

$$\log \frac{L_n(\alpha; X_1, \dots, X_n)}{L_n(\vartheta; X_1, \dots, X_n)} \xrightarrow{\mathbb{P}_\vartheta\text{-f.s.}} -\infty \quad \text{für } n \longrightarrow \infty,$$

mit anderen Worten, für  $\alpha \neq \vartheta$  gilt

$$\frac{L_n(\alpha; X_1, \dots, X_n)}{L_n(\vartheta; X_1, \dots, X_n)} \xrightarrow{\mathbb{P}_\vartheta\text{-f.s.}} 0 \quad \text{für } n \longrightarrow \infty.$$

Andererseits ist offensichtlich der Quotient für  $\alpha = \vartheta$  gleich Eins. □

Lemma 3.3 ist noch einmal ein Argument für die Vernünftigkeit des Maximum-Likelihood-Schätzers:  $L_n(\alpha; X_1, \dots, X_n)$  wird für  $\alpha$  fernab von  $\vartheta$  vergleichsweise zu  $L_n(\vartheta; X_1, \dots, X_n)$  klein sein (mit wachsendem  $n$  konvergiert der Quotient ja gegen Null), für  $\alpha$  in der Nähe von  $\vartheta$  auf Grund der Stetigkeit von  $\alpha \longrightarrow L_n(\alpha; X_1, \dots, X_n)$  nahe Eins. Verwendet man  $\hat{\vartheta}_n(X_1, X_2, \dots, X_n)$  als Schätzer für  $\vartheta$ , so wird man also erwarten können, daß dieser Schätzer in der Nähe von  $\vartheta$  liegt.

### Eigenschaften der Maximum-Likelihood-Schätzer:

Wir geben hier zwei wichtige Eigenschaften von Maximum-Likelihood-Schätzern für den Fall von Stichproben an, die aus unabhängigen, identisch verteilten Zufallsgrößen bestehen. Für die keineswegs einfachen Beweise sei auf die Literatur verwiesen.

## a) KONSISTENZ:

Im allgemeinen ist der Maximum-Likelihood-Schätzer nicht erwartungstreu, das heißt, es gilt i.a. nicht  $\mathbb{E}_\vartheta(\hat{\vartheta}_n(X_1, X_2, \dots, X_n)) = \vartheta$ . Die folgende Eigenschaft der Konsistenz besagt aber, daß man für große Stichprobenumfänge den Schätzer  $\hat{\vartheta}_n$  mit großer Wahrscheinlichkeit in der Nähe von  $\vartheta$  finden wird. (Wir beschränken uns mit der Formulierung auf den Fall, daß  $\mathbb{P}_\vartheta^{X_1}$  eine Dichte  $f_\vartheta(x)$  hat.)

- sei  $\Theta$  eine kompakte Teilmenge von  $\mathbb{R}^n$
- es gelte  $\{x \in \mathbb{R} : f_\alpha(x) > 0\}$  unabhängig von  $\alpha \in \Theta$
- wenn  $\alpha \neq \vartheta$ , so  $F_\alpha \neq F_\vartheta$  (Identifizierbarkeit des Modells bei  $\vartheta$ )
- für alle  $x \in \mathbb{R}$  sei  $\alpha \rightarrow f_\alpha(x)$  stetig
- es existiere eine  $\mathbb{P}_\vartheta$ -integrierbare Zufallsgröße  $H$  mit

$$\sup_\alpha |\log f(\alpha, X_1)| \leq H(\omega) \quad \mathbb{P}_\vartheta\text{-f.s.}$$

**Aussage 3.1.** *Unter den genannten Bedingungen ist jeder Maximum-Likelihood Schätzer  $\hat{\vartheta}_n$  konsistent im Sinne von*

$$\mathbb{P}_\vartheta(\|\hat{\vartheta}_n - \vartheta\| > \epsilon) \rightarrow 0 \quad \forall \epsilon > 0 \quad \forall \vartheta \in \Theta$$

*Beweis:*

s. Dacunha-Castelle, Duflo II, S. 126 f.

## b) ASYMPTOTISCHE NORMALITÄT:

Wir stellen weiter einige Voraussetzungen an unser statistisches Modell.

**Definition 3.4.** Es sei  $(\Omega, \mathcal{A}, \mathcal{P}, X)$  ein statistisches Modell mit  $\mathcal{P} = (\mathbb{P}_\vartheta, \vartheta \in \Theta)$ ,  $\Theta \subseteq \mathbb{R}^k$  und es sei  $\vartheta \in \Theta$ .

Dann heißt  $(\Omega, \mathcal{A}, \mathcal{P}, X)$  *regulär bei  $\vartheta$* , falls  $\Theta$  eine Umgebung von  $\vartheta$  ist, und falls  $L_n(\cdot; X(\omega))$  wie folgt gewählt werden kann:

**H1)** In einer Umgebung  $V$  von  $\vartheta$  mit  $V \subseteq \Theta$  ist die Funktion  $\alpha \rightarrow L_n(\alpha; x)$  für jedes  $x$  zweimal stetig differenzierbar.

**H2)**  $\text{grad} \log L_n(\vartheta; X(\cdot))$  ist ein zentrierter Zufallsvektor mit endlichen zweiten Momenten bezüglich  $\mathbb{P}_\vartheta$ .

Außerdem gilt

$$\begin{aligned} & \mathbb{E}_\vartheta \left( \frac{\partial}{\partial \vartheta_i} \log L_n(\vartheta; X) \cdot \frac{\partial}{\partial \vartheta_j} \log L_n(\vartheta; X) \right) \\ &= \mathbb{E}_\vartheta \left( \frac{\partial^2}{\partial \vartheta_i \partial \vartheta_j} \log L_n(\vartheta; X) \right) \\ &=: I_n^{(i,j)}(\vartheta) \end{aligned}$$

Die  $k \times k$ -Matrix  $I_n(\vartheta) := (I_n^{(i,j)}(\vartheta))_{i,j=1,\dots,k}$  heißt *Fisher-Informationsmatrix* für  $\vartheta$  auf der Basis von  $X = (X_1, X_2, \dots, X_n)$ .

**H3)**  $I_n(\vartheta)$  ist invertierbar.

Wir kehren zum ML-Schätzer zurück, betrachten aber nur den Fall, daß  $X_1$  unter jedem  $\mathbb{P}_\vartheta$  eine Dichte  $f_\vartheta$  besitzt.

$$l_n(\vartheta; X) = \log L_n(\vartheta; X) = \sum_{m=1}^n \log f_\vartheta(X_m)$$

Wir setzen

$$Y_n^i := \frac{\partial}{\partial \vartheta_i} l_n(\vartheta) = \sum_{m=1}^n \frac{\frac{\partial}{\partial \vartheta_i} f_\vartheta(X_m)}{f_\vartheta(X_m)} \quad \text{und}$$

$$Y_n := (Y_n^i)_{i=1,\dots,k} = \text{grad } l_n(\vartheta)$$

Die Vektoren

$$\left( \frac{\frac{\partial}{\partial \vartheta_i} f_\vartheta(X_m)}{f_\vartheta(X_m)} \right)_{i=1,\dots,k}$$

bilden für  $m \geq 1$  bezüglich  $\mathbb{P}_\vartheta$  unabhängige, identisch verteilte zentrierte Zufallsvektoren mit der Kovarianzmatrix  $I_1(\vartheta)$  (Beachte H3).

Nach dem zentralen Grenzwertsatz für zufällige Vektoren gilt:

$$\frac{1}{\sqrt{n}} Y_n(\vartheta) \xrightarrow{d(\mathbb{P}_\vartheta)} \mathcal{N}_k(0, I_1(\vartheta))$$

(Dacunha-Castelle, Dufflo I, Seite 225).

Diese Eigenschaft führt nach einer Reihe weiterer Rechnungen auf die folgende

**Aussage 3.2.** *Es sei  $(\Omega, \mathcal{A}, \mathcal{P}, X)$  ein an der Stelle  $\vartheta \in \Theta$  reguläres statistisches Modell. Die Verteilung  $\mathbb{P}_\vartheta^X$  habe bezüglich eines dominierenden Maßes  $\mu$  die Dichte  $f_\vartheta(x)$ ,  $x \in E$ ,  $\vartheta \in \Theta$ . Es sei weiterhin  $(X_1, X_2, \dots, X_n)$  eine klassische mathematische Stichprobe aus einer nach  $\mathbb{P}_\vartheta^{X_1}$  verteilten Grundgesamtheit (d.h.,  $X_1, X_2, \dots, X_n$  seien unabhängige, identisch nach  $\mathbb{P}_\vartheta^{X_1}$  verteilte Zufallsvariablen). Weiterhin gelte*

**H4)** Es existiert eine Umgebung  $V$  von  $\vartheta$ ,  $V \subseteq \Theta$ , und eine  $\mathbb{P}_\vartheta^{X_1}$ -integrierbare Funktion  $H$  auf  $\mathbb{R}^k$  mit

$$\left| \frac{\partial}{\partial \vartheta_i} \frac{\partial}{\partial \vartheta_j} \log f_\vartheta(x) \right| \leq H(x) \quad \vartheta \in V, \quad i, j = 1, \dots, n$$

Bezeichnet  $\hat{\vartheta}_n(X_1, X_2, \dots, X_n)$  einen Maximum-Likelihood-Schätzer für  $\vartheta$ , so gelte  $\hat{\vartheta}_n \xrightarrow{\mathbb{P}_\vartheta} \vartheta$  (Konsistenz).

Dann haben wir:

$$\begin{aligned} \sqrt{n}(\hat{\vartheta}_n - \vartheta) &\xrightarrow{d(P_\vartheta)} \mathcal{N}(0, I^{-1}(\vartheta)) \text{ und} \\ I(\vartheta)\sqrt{n}(\hat{\vartheta}_n - \vartheta) - \frac{1}{\sqrt{n}} \text{grad } l_n(\vartheta) &\xrightarrow{P_\vartheta} 0. \end{aligned}$$

Zum Beweis dieser Aussage sei ebenfalls auf Dacunha-Castelle, Duflo II, S. 127, verwiesen.

**Beispiele 3.1.** a) Normalverteilung

Es seien  $X_1, \dots, X_n$  unabhängige, identisch  $\mathcal{N}(\mu, \sigma^2)$ -verteilte Zufallsvariablen. Es sei  $\vartheta = (\mu, \sigma^2)^T \in \mathbb{R} \times (0, \infty) =: \Theta$

Folglich erhalten wir

$$\begin{aligned} \log f_\vartheta(x) &= -\frac{1}{2} \log(2\pi\sigma^2) - \frac{1}{2} \frac{(x - \mu)^2}{\sigma^2}, \\ \text{grad } \log f_\vartheta(x) &= \begin{pmatrix} \frac{x - \mu}{\sigma^2} \\ -\frac{1}{2\sigma^2} + \frac{(x - \mu)^2}{2\sigma^4} \end{pmatrix}, \\ \dot{l}_n(X_1, X_2, \dots, X_n) &= \begin{pmatrix} \sum_{m=1}^n \frac{(X_m - \mu)}{\sigma^2} \\ -\frac{n}{2\sigma^2} + \frac{1}{2} \sum_{m=1}^n \frac{(X_m - \mu)^2}{\sigma^4} \end{pmatrix} \end{aligned}$$

$\dot{l}_n = 0$  liefert also die Lösung  $\hat{\vartheta}_n(X_1, \dots, X_n) = (\hat{\mu}_n, \hat{\sigma}_n^2)^T$ , wobei

$$\begin{aligned} \hat{\mu}_n(X_1, X_2, \dots, X_n) &= \frac{1}{n} \sum_{m=1}^n X_m =: \bar{X}_n \\ \hat{\sigma}_n^2(X_1, X_2, \dots, X_n) &= \frac{1}{n} \sum_{m=1}^n (X_m - \bar{X}_n)^2 \end{aligned}$$

Dieses Modell ist regulär im oben genannten Sinne.

## b) Verschobene Exponentialverteilung

Es seien  $X_1, \dots, X_n$  unabhängige, identisch verteilte Zufallsvariablen mit Dichte

$$f_{\vartheta}(x) = \mathbf{1}_{[\xi, \infty)}(x) \lambda \exp\{-\lambda(x - \xi)\}, \quad x \in \mathbb{R}.$$

Es sei  $\vartheta = (\xi, \lambda)^T \in \mathbb{R} \times (0, \infty) =: \Theta$

(Skizzieren Sie die Dichte!)

Die Dichte  $f_{\vartheta}(x)$  ist bei festem  $x$  nicht bezüglich  $\vartheta$  differenzierbar. Bei festem  $x$  ist  $f_{\vartheta}(x)$  für  $\xi = x$  und  $\lambda = \frac{1}{x - \xi}$  maximal. Folglich erhalten wir

$$L_n(\vartheta; X_1, \dots, X_n) = \mathbf{1}_{[\xi, \infty)}(\min\{X_1, \dots, X_n\}) \lambda^n \exp\left\{-\lambda \sum_{m=1}^n X_m + \lambda \xi n\right\}$$

$$\begin{aligned} \text{und somit } \hat{\vartheta}_n(X_1, \dots, X_n) &= \arg \max_{\vartheta \in \Theta} L_n(\vartheta; X_1, \dots, X_n) \\ &= \left( \begin{array}{c} \min\{X_1, \dots, X_n\} \\ \left(\bar{X}_n - \min\{X_1, \dots, X_n\}\right)^{-1} \end{array} \right), \end{aligned}$$

also

$$\hat{\xi}_n = \min\{X_1, \dots, X_n\} \quad \text{und} \quad \hat{\lambda}_n = \left(\bar{X}_n - \min\{X_1, \dots, X_n\}\right)^{-1}.$$

Der Schätzer  $\hat{\vartheta}_n$  ist in diesem Fall konsistent aber nicht asymptotisch normalverteilt. Die Regularitätsvoraussetzung H2) ist verletzt.

**Ein einfacher Fall stochastischer Prozesse****1 AUTOREGRESSIVES SCHEMA ERSTER ORDNUNG:**

Es sei  $(\epsilon_n, n \geq 1)$  eine Folge reellwertiger, unabhängiger, identisch verteilter Zufallsgrößen,  $X_0 = x_0$  und  $x_0, \alpha$  seien reelle Zahlen. Wir definieren

$$X_n = \alpha X_{n-1} + \epsilon_n, \quad n \geq 1.$$

Die Folge  $(X_n, n \geq 1)$  heißt *autoregressive Folge erster Ordnung* oder *AR(1)-Folge*.

$\epsilon_1$  habe die Dichte  $f$ , die überall auf  $\mathbb{R}$  positiv sei.

Dann besitzt auch die Stichprobe  $X := (X_1, X_2, \dots, X_n)$  eine Dichte

$$f^X(x_1, x_2, \dots, x_n) = \prod_{m=1}^n f(x_m - \alpha x_{m-1}) = L_n(\alpha; x_1, x_2, \dots, x_n)$$



und es gilt

$$l_n(\alpha; x_1, x_2, \dots, x_n) = \sum_{m=1}^n \log f(x_m - \alpha x_{m-1}), \quad \dot{l}_n = - \sum_{m=1}^n x_{m-1} \frac{\dot{f}(x_m - \alpha x_{m-1})}{f(x_m - \alpha x_{m-1})}.$$

Die ML-Gleichung lautet:

$$\sum_{m=1}^n \frac{X_{m-1} \dot{f}(X_m - \hat{\alpha}_n X_{m-1})}{f(X_m - \hat{\alpha}_n X_{m-1})} = 0.$$

Im Spezialfall  $\epsilon_1 \sim \mathcal{N}(0, 1)$  gilt

$$l_n(\alpha; X_1, X_2, \dots, X_n) = \alpha \sum_{m=1}^n X_m X_{m-1} - \frac{\alpha^2}{2} \sum_{m=1}^n X_{m-1}^2$$

und indem man  $\dot{l}_n = \sum_{m=1}^n X_m X_{m-1} - \alpha \sum_{m=1}^n X_{m-1}^2 = 0$  setzt,

bekommt man einen Maximum-Likelihood-Schätzer für  $\alpha$ :

$$\hat{\alpha}_n = \frac{\sum_{m=1}^n X_m X_{m-1}}{\sum_{m=1}^n X_{m-1}^2}.$$

Es gilt

$$\hat{\alpha}_n - \alpha = \frac{\sum_{m=1}^n X_{m-1} (X_m - \alpha X_{m-1})}{\sum_{m=1}^n X_{m-1}^2} = \frac{\sum_{m=1}^n X_{m-1} \epsilon_m}{\sum_{m=1}^n X_{m-1}^2}.$$

Man beachte, daß

$$\left( \sum_{m=1}^n X_{m-1} \epsilon_m \right)_{n \geq 1} \text{ ein Martingal ist und } \left( \sum_{m=1}^n X_{m-1}^2 \right)_{n \geq 1} \text{ seine bedingte Varianz darstellt:}$$

$$\text{Var}_{\wp_n} \left( \sum_{m=1}^n X_{m-1} \epsilon_m \right) = \mathbb{E}_{\wp} \left( \left( \sum_{m=1}^n X_{m-1} \epsilon_m \right)^2 \middle| \wp_{n-1} \right) = \sum_{m=1}^n X_{m-1}^2.$$

$$(\wp_n := \sigma(X_1, X_2, \dots, X_n) = \sigma(\epsilon_1, \epsilon_2, \dots, \epsilon_n), \quad n \geq 1)$$

Für die Untersuchung der asymptotischen Eigenschaften von  $(\hat{\alpha}_n, n \geq 1)$  für  $n \rightarrow \infty$  bietet sich also die Martingaltheorie an.