

# Stochastik–Praktikum

## Parametrische Schätztheorie

Thorsten Dickhaus

Humboldt-Universität zu Berlin

05.10.2010



# Prolog

$X : \Omega^{-1} \rightarrow \Omega$  Zufallsgröße, die Experiment beschreibt.

Ein statistisches Modell (statistisches Experiment) ist ein Tripel  $(\Omega, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$ .

Ein Beispiel zur Illustration:

Binomial-Modell:

$Y = (Y_i)_{i=1, \dots, n}$ ,  $Y_i \sim \text{Bernoulli}(p)$ ,

$Y_i$  stoch. unabhängige Zufallsvariablen mit Werten in  $\{0, 1\}$ ,

$p \in (0, 1)$  Trefferw'keit,  $n \in \mathbb{N}$ ,  $X = \sum_{i=1, \dots, n} Y_i$

$\Omega = \{0, \dots, n\}$ ,  $\mathcal{F} = 2^\Omega$ ,

$\vartheta = (n, p) \in \mathbb{N} \times (0, 1) = \Theta$

# Schätzfunktionen und Eigenschaften

$T : \Omega \rightarrow \Theta$  heißt Schätzfunktion (Vorschrift).

Die Zufallsvariable  $T(X)$  heißt Schätzer,  
 $T(x)$  Schätzwert (Realisierung).

## Definition (Eigenschaften von $T(X)$ )

- $T(X)$  unverzerrt (unbiased), falls  $\mathbb{E}[T(X)] = \vartheta$ .
- $T(X)$  effizient, falls  $\text{Var}(T(X))$  minimal (in einer Klasse von Schätzern).
- $T(X) = T_n(X)$  konsistent, falls  $T(X) \xrightarrow{\mathbb{P}} \vartheta$ .
- $T(X)$  suffizient, falls  $T(X)$  alle Information der Stichprobe (über  $\vartheta$ ) ausnutzt.

## Varianz-Bias Zerlegung

$\text{MSE}_\vartheta(T(X)) = \mathbb{E}_\vartheta[(T(X) - \vartheta)^2]$  **mittlerer quadratischer Fehler**

Es gilt:

$$\begin{aligned} \text{MSE}_\vartheta(T(X)) &= \mathbb{E}_\vartheta[(T(X) - \mathbb{E}_\vartheta[T(X)] + \mathbb{E}_\vartheta[T(X)] - \vartheta)^2] \\ &= \mathbb{E}_\vartheta[(T(X) - \mathbb{E}_\vartheta[T(X)])^2] + (\mathbb{E}_\vartheta[T(X)] - \vartheta)^2 \\ &\quad + \underbrace{2(\mathbb{E}_\vartheta[T(X)] - \mathbb{E}_\vartheta[T(X)])(\mathbb{E}_\vartheta[T(X)] - \vartheta)}_{=0} \end{aligned}$$

Also:  $\text{MSE}_\vartheta(T(X)) = \text{Var}_\vartheta(T(X)) + (\mathbb{E}_\vartheta[T(X)] - \vartheta)^2.$

# Übersicht

- 1 Momentenmethode
- 2 Maximum Likelihood
- 3 Kleinste Quadrate
- 4 Konfidenzintervalle

# Übersicht

- 1 Momentenmethode
- 2 Maximum Likelihood
- 3 Kleinste Quadrate
- 4 Konfidenzintervalle

# Momente

## Definition

Das  $k$ -te Moment einer Zufallsvariable  $X$  ist definiert als

$$\mathbb{E}[X^k] = \begin{cases} \sum_{x \in \Omega} x^k f(x), & \text{falls } X \text{ diskret,} \\ \int_{\Omega} x^k f(x) dx, & \text{falls } X \text{ stetig.} \end{cases}$$

Dabei bezeichnet  $f$  die Verteilungsdichte bzw. die Wahrscheinlichkeitsfunktion von  $X$ .

# Momentenschätzung (MOM)

Sei  $\mu_k := \mathbb{E}[X^k]$ .

Liege eine iid. Stichprobe  $X_1, \dots, X_n$  vom Umfang  $n$  für das interessierende statistische Experiment vor.

Dann ist der MOM-Schätzer  $\hat{\mu}_k$  für  $\mu_k$  gegeben durch

$$\hat{\mu}_k = \frac{\sum_{i=1}^n X_i^k}{n}.$$

# Momentenschätzer: Beispiele

Habe  $X$  endliches zweites Moment.

Nach der Momentenmethode gilt:

- 1  $\hat{\mu} = \bar{X}_n$  (arithmetischer Mittelwert)
- 2  $\hat{\mu}_2 = \sum_{i=1}^n X_i^2 / n$
- 3  $\hat{\sigma}^2 = \hat{\mu}_2 - \hat{\mu}^2$ , da  $\text{Var}(X) = \mathbb{E}[X^2] - \mathbb{E}^2[X]$

Unter 3. zeigt sich, dass aus Momenten ableitbare Parameter bei der Momentenmethode durch „plug-in“ geschätzt werden.

# Momentenschätzer: Eigenschaften

Falls ein Momentenschätzer für einen Parameter  $\vartheta$  von Interesse verfügbar ist, so gilt für  $\hat{\vartheta}$ :

- Einfach aus Stichprobenmomenten zu berechnen
- Asymptotisch erwartungstreu
- Für finite Stichprobenumfänge oftmals verzerrt
- Immer konsistent
- Oft weder effizient noch suffizient

# Übersicht

- 1 Momentenmethode
- 2 Maximum Likelihood**
- 3 Kleinste Quadrate
- 4 Konfidenzintervalle

# Likelihood-Funktion

## Definition

Statistisches Experiment  $(\Omega, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta})$  sei gegeben.

Zufallsexperiment  $(X_i)_{i=1, \dots, n}$  sei durchgeführt worden.

Dann definieren wir

$$L(\vartheta) = \prod_{i=1}^n \mathbb{P}_\vartheta(X_i = x_i).$$

$L(\vartheta)$  approximiert die Wahrscheinlichkeit dafür, die konkret realisierte Stichprobe  $(x_1, \dots, x_n)$  unter  $\vartheta$  zu beobachten.

# Maximum Likelihood-Schätzer

Nach der MLE-Schätzmethode wird  $\vartheta$  durch

$$\hat{\vartheta} = \arg \max_{\vartheta \in \Theta} L(\vartheta)$$

geschätzt.

In vielen Modellen ist die Maximalstelle eindeutig bestimmt (Konkavität von  $L!$ ).

## Maximum Likelihood-Schätzung: Beispiel

Wir betrachten das Binomialmodell aus der Einleitung mit  $n = 10$  fest vorgegeben.

Es werden neun „Treffer“ beobachtet.

$$L(p) = \binom{10}{9} p^9 (1-p)$$

$$\ln L(p) = \ln \binom{10}{9} + 9 \ln(p) + \ln(1-p)$$

$$\frac{dL(p)}{dp} = \frac{9}{p} - \frac{1}{1-p}$$

Es ergibt sich  $\hat{p} = 9/10$ .

# Maximum Likelihood-Schätzung: Eigenschaften

## Vorteile:

- Universelles Schätzprinzip, vielseitig anwendbar
- Stets konsistent und suffizient
- **Asymptotisch** erwartungstreu und effizient
- Beste asymptotisch normalverteilte Schätzer

## Nachteile:

- Likelihoodfunktion bzw. Optimierungsaufgabe unter Umständen nicht-trivial
- Zum Teil komplizierte Numerik erforderlich
- **Für finites  $n$  zum Teil erheblich verzerrt!**

# Übersicht

- 1 Momentenmethode
- 2 Maximum Likelihood
- 3 Kleinste Quadrate**
- 4 Konfidenzintervalle

# Fehlerquadratsummenminimierung

## Modellbildung:

Stichprobe  $(x_1, \dots, x_n)$  setzt sich **additiv** aus einer Funktion  $f(\vartheta)$  des Parameters und einer Störung (Rauschen) zusammen.

## Definition

Die Fehlerquadratsumme ist definiert durch

$$S(\vartheta) = \sum_{i=1}^n (x_i - f(\vartheta))^2.$$

OLS-Methode: Minimiere  $S(\vartheta)$  bezüglich  $\vartheta$  !

## OLS-Methode: Beispiel

Betrachte einfache lineare Regression von  $Y$  auf  $X$  wie in Tag 1 thematisiert.

Gesucht wird also die „beste“ Approximation von  $Y$  durch eine lineare Funktion in  $X$ . Also:  $f(\vartheta) = f(\alpha, \beta) = \alpha + \beta X$ .

Seien Wertepaare  $(x_1, y_1), \dots, (x_n, y_n)$  beobachtet worden.

$$S(\alpha, \beta) = \sum_{i=1}^n (y_i - (\alpha + \beta x_i))^2.$$

## OLS-Methode: Beispiel (II)

$$\frac{\partial \mathcal{S}(\alpha, \beta)}{\partial \alpha} = -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i),$$

$$\frac{\partial \mathcal{S}(\alpha, \beta)}{\partial \beta} = -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i) x_i,$$

$$\hat{\alpha} = \bar{y}_n - \hat{\beta} \bar{x}_n,$$

$$\hat{\beta} = \frac{\sum_{i=1}^n (x_i - \bar{x}_n)(y_i - \bar{y}_n)}{\sum_{i=1}^n (x_i - \bar{x}_n)^2} = \frac{s_{xy}}{s_x^2}.$$

# Übersicht

- 1 Momentenmethode
- 2 Maximum Likelihood
- 3 Kleinste Quadrate
- 4 Konfidenzintervalle**

# Bereichsschätzungen

Statistisches Experiment  $(\Omega, \mathcal{F}, (\mathbb{P}_\vartheta)_{\vartheta \in \Theta \subset \mathbb{R}})$  sei gegeben.

## Definition

Ein Konfidenzintervall  $I = [\hat{\vartheta}_u, \hat{\vartheta}_o]$  besteht aus zwei messbaren Abbildungen  $\hat{\vartheta}_{u/o} : \Omega \rightarrow \Theta$  mit der Eigenschaft

$$\forall x \in \Omega : \mathbb{P}_\vartheta(\hat{\vartheta}_u(x) \leq \vartheta \leq \hat{\vartheta}_o(x)) \geq 1 - \alpha$$

für ein vorgegebenes Konfidenzniveau  $(1 - \alpha)$ ,  $\alpha \in (0, 1)$ .

In der Praxis werden die Schätzer  $\hat{\vartheta}_u$  und  $\hat{\vartheta}_o$  so ausgewählt, dass sich eine minimale Länge von  $I$  ergibt (Informativität!).

## Konfidenzintervalle unter Normalverteilung

Sei  $T(X)$  ein unverzerrter, **normalverteilter** Punktschätzer für  $\vartheta$ .

Dann wird die Länge von  $I$  genau dann minimal, falls  $I$  symmetrisch um  $T(x)$  ist.

$$\begin{aligned}
 \mathbb{P}_{\vartheta}(T(X) - c \leq \vartheta \leq T(X) + c) &= 1 - \alpha \\
 \iff \mathbb{P}_{\vartheta}(|T(X) - \vartheta| \leq c) &= 1 - \alpha \\
 \iff \mathbb{P}_{\vartheta}(T(X) - \vartheta \leq c) &= 1 - \alpha/2 \\
 \iff \mathbb{P}_{\vartheta}\left(\frac{T(X) - \vartheta}{\sigma_T} \leq \frac{c}{\sigma_T}\right) &= 1 - \alpha/2 = \Phi\left(\frac{c}{\sigma_T}\right) \\
 \iff c &= \sigma_T \Phi^{-1}(1 - \alpha/2).
 \end{aligned}$$

## Ausblick: Höhere Dimensionen (von $\Theta$ )

Falls  $\Theta$  hochdimensional ist, z.B.  $\Theta \subseteq \mathbb{R}^k, k > 2$ ,  
so sind klassische Schätzverfahren oftmals nicht optimal.

### Moderne Schätzverfahren sind z. B.:

- Regularisierte Schätzverfahren (Strafterm für Komplexität)
- Shrinkage-Schätzer (James-Stein etc.)
- Statistische Lerntheorie (ERM, SRM, ...)