

Schätzen und Testen I in 90 Minuten

Autorin: Christiane Fuchs

Bearbeitet von: Julia Sommer, Ludwig Bothmann, David Rügamer

2. Februar 2016

1. Einführung in statistische Modelle und Inferenzkonzepte
2. Klassische Schätz- und Testtheorie
3. Likelihood-Inferenz
4. Bayes-Inferenz

Kapitel 1:

Einführung in statistische Modelle und Inferenzkonzepte

Parametrische Modelle $X \sim f(x|\theta)$ für $\theta \in \Theta$

▶ Verteilungsfamilien

- ▶ Darstellung über Standardverteilung mit **Lokalisationsparameter** a und **Skalenparameter** b

$$\frac{1}{b} f_0\left(\frac{x-a}{b}\right)$$

- ▶ **Exponentialfamilien**

$$f(x|\theta) = h(x) \exp\left(b(\theta) + \gamma(\theta)' \mathbf{T}(x)\right)$$

i.A. Fisher-regulär, schöne Eigenschaften

- ▶ übersicht über (generalisierte) lineare parametrische Modelle

Non- und semi-parametrische Modelle

- ▶ Schätzen & Testen II

Konzepte:

- ▶ Statistische Entscheidungstheorie
- ▶ Klassische Schätz- und Testtheorie
- ▶ Likelihood-Inferenz
- ▶ Bayes-Inferenz

Kapitel 2:

Klassische Schätz- und Testtheorie

Gewünschte Eigenschaften einer Statistik / eines Schätzers $\hat{\theta} = T(X)$

Suffizienz

„keine Info verschenken“

Faktorisierung (Neyman)

Fisher-Info

Minimalsuffizienz

„suffizient & eindeutig“

Satz: Likelihoodquotient

Lehmann-Scheffé:
Suffizient + vollständig

MSE-optimal

„Bias+Varianz minimieren“

Zulässige Schätzer

=> Einschränkung auf erwartungstreue Schätzer

Erwartungstreue

„unverzerrt, kein Bias“

Effizienz

„Varianz möglichst klein“

UMVU

Fisher-Info

Informationsungleichung
& Cramer-Rao-Schranke

Rao-Blackwellisierung

Asymptotische Eigenschaften einer Folge von Schätzern $\hat{\theta}_n = T(X_1, \dots, X_n)$

- ▶ Asymptotische Erwartungstreue
- ▶ Konsistenz ($MSE_{\theta}(\hat{\theta}_n) \rightarrow 0$ für alle θ und $n \rightarrow \infty$)
- ▶ Asymptotische Normalität (\sqrt{n} -Normierung, Matrix-Normierung)
 - ▶ Delta-Methode
- ▶ Asymptotische Effizienz (BAN-Schätzer)
 - ▶ Asymptotische Cramer-Rao-Schranke
 - ▶ Fisher-Regularität

Gewünschte Eigenschaften eines Tests

Testproblem:


$$H_0 : \theta \in \Theta_0 \quad \text{vs.} \quad H_1 : \theta \in \Theta_1$$

Fehler 1. Art: $\alpha \rightarrow$ fest vorgegeben

Fehler 2. Art: $\beta \rightarrow$ minimieren (bzw. Macht maximieren)

Gesucht ist unter allen Tests ϕ
 der **gleichmäßig beste Test** ϕ^*
 zum Niveau α (UMP)

- Gütefunktion



θ

UMP-Test für einfache Hypothesen

$$H_0 : \theta = \theta_0 \quad \text{vs.} \quad H_1 : \theta = \theta_1$$

► **Satz von Neyman-Pearson:**

Der eindeutig bestimmte **UMP-Test zum exakten Niveau α** ist ein **randomisierter LQ-Test**, d.h. von der Form

$$\phi^*(x) = \begin{cases} 1, & \Lambda(x) > k & H_0 \text{ ablehnen} \\ \gamma^*, & \Lambda(x) = k & \text{randomisieren} \\ 0, & \Lambda(x) < k & H_0 \text{ beibehalten} \end{cases}$$

mit Konstante $k > 0$ und $0 \leq \gamma^* < 1$.

► **Niveaubedingung zur Bestimmung von γ^* :**

$$\mathbb{P}_{\theta_0}(\Lambda(x) > k) + \gamma^* \mathbb{P}_{\theta_0}(\Lambda(x) = k) = \alpha$$

UMP-Test für einseitige Hypothesen

$$H_0 : \theta \leq \theta_0 \quad \text{vs.} \quad H_1 : \theta > \theta_0$$

► **Satz (UMP-Test bei MLQ):**

Falls die Verteilungsfamilie MLQ in $T(x)$ (d.h. der Likelihoodquotient $\Lambda(\cdot)$ ist monoton steigend in $T(x)$), gibt es einen **UMP-Test zum exakten Niveau α** , nämlich

$$\phi^*(x) = \begin{cases} 1, & T(x) > c & H_0 \text{ ablehnen} \\ \gamma^*, & T(x) = c & \text{randomisieren} \\ 0, & T(x) < c & H_0 \text{ beibehalten} \end{cases}$$

mit Konstante $0 \leq \gamma^* < 1$.

► **Niveaubedingung zur Bestimmung von γ^* und c :**

$$\mathbb{P}_{\theta_0}(T(x) > c) + \gamma^* \mathbb{P}_{\theta_0}(T(x) = c) = \alpha$$

UMPU-Test für zweiseitige Hypothesen

$$H_0 : \theta = \theta_0 \quad \text{vs.} \quad H_1 : \theta \neq \theta_0$$

- ▶ Zusätzliche Einschränkung auf unverfälschte Tests
- ▶ Entsprechende Bestimmung eines UMPU-Tests

Veranschaulichung der Randomisierung

Testproblem:

$$H_0 : \theta \in \Theta_0 \quad \text{vs.} \quad H_1 : \theta \in \Theta_1$$


Randomisierter Test:

$$\phi(x) = \begin{cases} 1 & , \quad x \in B_1 \\ \gamma(x) & , \quad x \in B_{10} \\ 0 & , \quad x \in B_0 \end{cases}$$

B_1 strikter Ablehnungsbereich

B_0 strikter Annahmehbereich

B_{10} Randomisierungsbereich, Indifferenzbereich



Klassische Schätz- und Testtheorie

was sonst noch behandelt wurde...

- ▶ Bereichsschätzung und Konfidenzintervalle
- ▶ Dualität von Konfidenzbereichen und Tests
- ▶ Multiples Testen

Kapitel 3:

Likelihood-Inferenz

Likelihood-Inferenz

- ▶ Schätzkonzept: Maximierung der Likelihood
- ▶ numerische Methoden zur Bestimmung des ML-Schätzers
- ▶ Asymptotische Eigenschaften
 - ▶ Konsistenz
 - ▶ Erwartungstreue
 - ▶ Normalität
 - ▶ **ML-Schätzer sind BAN-Schätzer** (unter Fisher-Regularität)
- ▶ Testen linearer Hypothesen
 - ▶ Konstruktion von Teststatistiken durch Ausnutzen von Verteilungsaussagen über Likelihood, Score-Funktion oder den ML-Schätzer selbst
- ▶ Asymptotische Konfidenzintervalle
- ▶ Inferenz nach Modellselektion


Fehlspezifikation

Gründe für Fehlspezifikation:

- ▶ falsche Verteilungsannahme
- ▶ falsche Erwartungswertstruktur
- ▶ falsche Kovarianzstruktur

Werkzeuge:

- ▶ Kullback-Leibler-Distanz
- ▶ Quasi-Likelihood



Kapitel 4:

Bayes-Inferenz

Basiskomponenten in der Bayes-Inferenz

- ▶ $p(\theta)$ Priori-Verteilung
- ▶ $f(x|\theta)$ Daten-Verteilung, Likelihood
- ▶ $f(\theta|x)$ Posteriori-Verteilung

$$f(\theta|x) = \frac{f(x|\theta)p(\theta)}{f(x)} \propto f(x|\theta)p(\theta)$$

- ▶ $f(\tilde{x}|x)$ prädiktive Verteilung

Modelle

- ▶ Modelle mit einem Parameter
- ▶ Multivariate Normalverteilung
- ▶ Dirichlet-Multinomial-Modell
- ▶ Bayesianisches LM und GLM

Dazu berechnet:

- ▶ gemeinsame Posteriori
- ▶ vollbedingte Dichten / Full Conditionals
- ▶ Posteriori-Randdichten / marginale Posterioridichten
- ▶ a posteriori prädiktive Verteilung

Wahl einer Priori Verteilung

- ▶ **konjugiert**, semi-konjugiert
 - ▶ Posteriori analytisch berechenbar, keine Simulation nötig
- ▶ beliebige Verteilung, die das Vorwissen gut ausdrückt
- ▶ **nicht-informativ**
 - ▶ 'Die Daten für sich sprechen lassen'
 - ▶ Jeffreys' Priori: Posterioriverteilung wird von den Daten dominiert, nicht vom Vorwissen. Erfüllt das Invarianzprinzip.
 - ▶ Alternativ: flache Priori, Priori mit maximaler Varianz

Punkt- und Intervallschätzer

Punktschätzer:

- ▶ Erwartungswert, Modus, Median der Posterioriverteilung

Intervallschätzer:

- ▶ Gleichendiges Kreditabilitätsintervall: $\alpha/2$ und $(1 - \alpha/2)$ – Quantil der Posterioriverteilung
- ▶ HPD-Kreditabilitätsintervall: Kleinstes $(1 - \alpha)$ – Kreditabilitätsintervall

Algorithmen

Ziel: Simulation aus der analytisch nicht zugänglichen Posteriori-Verteilung.

- ▶ Direkte Simulation
- ▶ Markov Chain Monte Carlo Simulation
 - ▶ Gibbs
 - ▶ Metropolis-Hastings

⇒ **Schätzung** der theoretischen Momente der Posteriori-Verteilung durch empirische Analoga. Z.B. Erwartungswert durch arithmetisches Mittel oder theoretische Quantile durch empirische Quantile der simulierten Zufallszahlen.

Direkte Simulation von $\theta = (\gamma, \tau)'$

Voraussetzung: Simulation aus $f(\gamma)$ und $f(\tau|\gamma)$ möglich.

Algorithmus:

- ▶ Wiederhole für $k = 1, \dots, K$:
 - Schritt 1: Ziehe $\gamma^{(k)}$ aus $f(\gamma)$.
 - Schritt 2: Ziehe $\tau^{(k)}$ aus $f(\tau|\gamma^{(k)})$.
- ▶ Man erhält K Paare $\theta^{(k)} = (\gamma^{(k)}, \tau^{(k)})'$ aus der Verteilung von θ .

Empirischer CDF-Sampler zur Simulation von θ

Voraussetzung: $f(\theta)$ muss bis auf Proportionalitätskonstante bekannt sein (und θ skalar).

Algorithmus:

- ▶ Diskretisiere den Träger von θ in eine Menge von N Punkten $x_1 \leq \dots \leq x_N$.
- ▶ Evaluiere den Kern von $f(\theta)$ an $x_1 \leq \dots \leq x_N$, um Werte f_1, \dots, f_N zu erhalten.
- ▶ Schätze die Proportionalitätskonstante c über $c = f_1 + \dots + f_N$.
- ▶ Ziehe Zufallszahlen aus $x_1 \leq \dots \leq x_N$ gemäß den Wahrscheinlichkeiten $f_1/c, \dots, f_N/c$.

Gibbs-Sampler zur Simulation von $\theta = (\theta_1, \dots, \theta_n)'$

$$\begin{aligned}\theta_{-i} &= (\theta_1, \dots, \theta_{i-1}, \theta_{i+1}, \dots, \theta_n)' \\ \theta_{-i}^{(k)} &= (\theta_1^{(k)}, \dots, \theta_{i-1}^{(k)}, \theta_{i+1}^{(k-1)}, \dots, \theta_n^{(k-1)})'\end{aligned}$$

Voraussetzung: Simulation von Zufallszahlen aus den vollbedingten Dichten $f(\theta_i | \theta_{-i})$ muss möglich sein.

Algorithmus:

- ▶ Wähle einen Startwert $\theta^{(0)}$.
- ▶ Wiederhole für $k = 1, \dots, K$:
 - ▶ Für $i = 1, \dots, n$: Ziehe $\theta_i^{(k)}$ aus $f(\theta_i | \theta_{-i}^{(k)})$.
- ▶ Nach einer ausreichenden Zahl M von Wiederholungen können die Ziehungen $\theta^{(M+1)}, \dots, \theta^{(K)}$ als Ziehungen aus $f(\theta)$ angesehen werden.

Metropolis-Hastings-Algorithmus zur Simulation von $\boldsymbol{\theta} = (\theta_1, \dots, \theta_n)'$

Voraussetzung: Der Kern der vollbedingten Dichten $f(\theta_i | \boldsymbol{\theta}_{-i}, \mathbf{x})$ oder der gemeinsamen Posteriori $f(\boldsymbol{\theta} | \mathbf{x})$ muss bekannt sein.


Algorithmus:

- ▶ Wähle einen Startwert $\boldsymbol{\theta}^{(0)}$.
- ▶ Wiederhole für $k = 1, \dots, K$:
 - ▶ Für $i = 1, \dots, n$:
 - ▶ Ziehe Y aus einer geeigneten Vorschlagsdichte $q(\cdot | \theta_i^{(k-1)}, \boldsymbol{\theta}_{-i}^{(k)})$.
 - ▶ Setze $\theta_i^{(k)} := Y$ mit Wahrscheinlichkeit

$$\alpha(Y, \theta_i^{(k-1)}) = \min \left\{ 1, \frac{f(Y | \boldsymbol{\theta}_{-i}^{(k)})}{f(\theta_i^{(k-1)} | \boldsymbol{\theta}_{-i}^{(k)})} \cdot \frac{q(\theta_i^{(k-1)} | Y, \boldsymbol{\theta}_{-i}^{(k)})}{q(Y | \theta_i^{(k-1)}, \boldsymbol{\theta}_{-i}^{(k)})} \right\}.$$

- ▶ Ansonsten setze $\theta_i^{(k)} := \theta_i^{(k-1)}$.
- ▶ Nach einer ausreichenden Zahl M von Wiederholungen können die Ziehungen $\boldsymbol{\theta}^{(M+1)}, \dots, \boldsymbol{\theta}^{(K)}$ als Ziehungen aus $f(\boldsymbol{\theta})$ angesehen werden.

Konvergenzuntersuchungen



Likelihood- und Bayes-Inferenz im Vergleich

	Likelihood	Bayes
Stützmaß für Inferenz	Likelihood-Funktion	Posteriori-Verteilung
a priori	$f(x \theta)$ Dichte von X	$f(x \theta)$ Dichte von X und $p(\theta)$ Dichte von θ
a posteriori	Likelihood: $L(\theta) = f(x \theta)$. Wie wahrscheinlich ist es gewesen, x zu beobachten, wenn θ der 'wahre' Parameter ist.	Posteriori: $f(\theta x)$ beschreibt die Verteilung des Parameters nach Beobachtung von x .
Parametrische Modellierung	Unbekannter Parameter θ ist fest, Wahrscheinlichkeits- aussagen betreffen nur den Schätzer $\hat{\theta}_n$.	Unbekannter Parameter θ ist stochastisch, hat eine Verteilung.
Berechnung & Werkzeuge	Likelihood maximieren <ul style="list-style-type: none"> ▶ analytisch ▶ numerisch (Newton Raphson, ...) 	Posteriori berechnen <ul style="list-style-type: none"> ▶ analytisch ▶ numerisch über Simulation / MCMC