

Inhalt

1. Einführung in statistische Modelle und Inferenzkonzepte
 - Statistische Modelle
 - Konzepte der statistischen Inferenz
2. Klassische Schätz- und Testtheorie
 - Klassische Schätztheorie
 - Klassische Testtheorie
 - Bereichsschätzung und Konfidenzintervalle
 - Multiples Testen
3. Likelihood-Inferenz
 - Parametrische Likelihood-Inferenz
 - Maximum-Likelihood-Schätzung
 - Testen linearer Hypothesen und Konfidenzintervalle
 - Fehlspezifikation, Quasi-Likelihood und Schätzgleichungen

3.1 Parametrische Likelihood-Inferenz

Situation: $\mathcal{P}_\theta = \{f(\mathbf{x}|\theta) : \theta \in \Theta\}$, $\Theta \subseteq \mathbb{R}^p$, $p \ll n$, p konstant für $n \rightarrow \infty$. $f(\mathbf{x}|\theta)$ ist eine diskrete oder stetige oder allgemeiner eine Radon-Nikodym-Dichte.

Definition 3.1 (Likelihoodfunktion)

Die Likelihoodfunktion von $\theta \in \Theta$,

$$L(\theta) = f(\mathbf{x}|\theta),$$

ist definiert als die Dichte der beobachteten Daten

$\mathbf{X} = (X_1, \dots, X_n) = \mathbf{x} = (x_1, \dots, x_n)$, betrachtet als Funktion von θ . Mit $L(\theta)$ ist auch $\tilde{L}(\theta) = \text{const} \times L(\theta)$ eine Likelihoodfunktion.

3.1 Parametrische Likelihood-Inferenz

Zu unterscheiden sind folgende häufige Situationen:

1. X_1, \dots, X_n sind i.i.d. wie $X_i \sim f_1(x|\theta)$. Es gilt die Faktorisierung

$$L(\theta) = \prod_{i=1}^n f_1(x_i|\theta).$$

2. X_1, \dots, X_n — bzw. $Y_1|\mathbf{z}_1, \dots, Y_n|\mathbf{z}_n$ im Regressionsfall bei einer Zielvariable Y und Kovariablenvektor \mathbf{z} — sind unabhängig, aber nicht mehr identisch verteilt. Es gilt die Faktorisierung

$$L(\theta) = \prod_{i=1}^n f_i(x_i|\theta).$$

3.1 Parametrische Likelihood-Inferenz

- Die Paare $(X_1^d, X_1^s), \dots, (X_i^d, X_i^s), \dots, (X_n^d, X_n^s)$ sind unabhängig, die einzelnen Komponenten innerhalb eines Paares unter Umständen abhängig. Die Indizes s, d beziehen sich auf stetige bzw. diskrete Variablen.

Eine derartige Datenlage ergibt sich beispielsweise bei Survivaldaten mit stetigen Überlebenszeiten und einem diskreten Zensierungsindikator $X_i^d = I(C_i \leq T_i)$, wobei C_i bzw. T_i den Zensierungs- bzw. Verweildauerprozess bezeichnen.

3.1 Parametrische Likelihood-Inferenz

4. Zeitlich korrelierte Daten / Stichprobenvariablen $X_1, \dots, X_t, \dots, X_n$ mit Dichtefunktion

$$\begin{aligned} f(x_1, \dots, x_t, \dots, x_n | \theta) = \\ f(x_n | x_{n-1}, \dots, x_t, \dots, x_1; \theta) \cdot \dots \cdot f(x_{n-1} | x_{n-2}, \dots, x_1; \theta) \cdot \dots \\ \cdot f(x_2 | x_1; \theta) f(x_1 | \theta). \end{aligned}$$

Bei Markov-Ketten erster Ordnung mit der Eigenschaft

$$f(x_n | x_{n-1}, \dots, x_1; \theta) = f(x_n | x_{n-1}; \theta)$$

vereinfacht sich die Likelihood zu

$$L(\theta) = \left(\prod_{i=2}^n f(x_i | x_{i-1}; \theta) \right) f(x_1 | \theta).$$

3.1 Parametrische Likelihood-Inferenz

Beispiel 3.1 (zu diesen vier Situationen)

1. Siehe Statistik IV bzw. Grundstudium.
2. Regressionssituationen (Querschnittsdaten) mit unabhängigen Zielvariablen $Y_1|\mathbf{z}_1, \dots, Y_n|\mathbf{z}_n$ und festen Kovariablen \mathbf{z}_i : z.B.
 - ▶ klassisches lineares Modell: $Y_i|\mathbf{z}_i \sim N(\mathbf{z}_i^\top \boldsymbol{\beta}, \sigma^2)$,
 - ▶ Logit- oder Probitmodell: $Y_i|\mathbf{z}_i \sim \text{Bin}(1, \pi_i = h(\mathbf{z}_i^\top \boldsymbol{\beta}))$,
 - ▶ Poisson-Regression: $Y_i|\mathbf{z}_i \sim \text{Po}(\lambda_i = h(\mathbf{z}_i^\top \boldsymbol{\beta}))$.
4. Markov-Ketten, autoregressive Modelle für Zeitreihen/Longitudinaldaten.

3.1 Parametrische Likelihood-Inferenz

Autoregressiver Prozess 1. Ordnung: Sei

$$X_t = \alpha + \gamma X_{t-1} + \varepsilon_t$$

mit $\varepsilon_t \stackrel{\text{i.i.d.}}{\sim} N(0, \sigma^2)$ oder — mit zusätzlichem (zeitabhängigen) Kovariablenvektor \mathbf{z}_t —

$$X_t = \alpha + \gamma X_{t-1} + \mathbf{z}_t^\top \boldsymbol{\beta} + \varepsilon_t.$$

In letzterem Fall hat die Likelihood die Form

$$L(\theta) = \left(\prod_{t=2}^n f_t(x_t | x_{t-1}; \theta) \right) f_1(x_1)$$

mit

$$f_t(x_t | x_{t-1}; \theta) = \phi(x_t | \alpha + \gamma x_{t-1} + \mathbf{z}_t^\top \boldsymbol{\beta}, \sigma^2),$$

wobei $\phi(x | \mu, \tau^2)$ den Wert der Normalverteilungsdichte mit Erwartungswert μ und Varianz τ^2 an der Stelle x bezeichnet.

3.1 Parametrische Likelihood-Inferenz

Beispiel 3.2.

Wir betrachten unabhängige, aber (teils) unvollständige Ziehungen aus $N(\theta, 1)$.

1. **Ziehung:** Es sei $x_1 = 2.45$. Dann ist

$$L_1(\theta) = \phi(x_1 - \theta) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}(2.45 - \theta)^2\right).$$

3.1 Parametrische Likelihood-Inferenz

2. **Ziehung:** Es sei nur $0.9 < x_2 < 4$ bekannt (unvollständige oder intervallzensierte Beobachtung). Die Likelihood lautet dann:

$$L_2(\theta) = \mathbb{P}_\theta(0.9 < X_2 < 4) = \Phi(4 - \theta) - \Phi(0.9 - \theta).$$

Formal könnte man auch eine binäre Variable

$$X_2^d = \begin{cases} 1, & 0.9 < X_2 < 4, \\ 0, & \text{sonst} \end{cases}$$

mit Dichtefunktion

$$f_2^d(1) = \mathbb{P}(X_2^d = 1) = \Phi(4 - \theta) - \Phi(0.9 - \theta)$$

definieren.

3.1 Parametrische Likelihood-Inferenz

3. Ziehung: z_1, \dots, z_n seien i.i.d. Realisierungen aus $N(\theta, 1)$.
Bekannt sei aber nur

$$x_3 = \max_{1 \leq i \leq n} z_i = z_{(n)}.$$

Der Rest sind fehlende Werte („missing values“).
Die Verteilungsfunktion von $X_3 = Z_{(n)}$ ist

$$\begin{aligned} F_\theta(z_{(n)}) &= \mathbb{P}_\theta(Z_{(n)} \leq z_{(n)}) = \mathbb{P}_\theta(Z_i \leq z_{(n)} \forall i) \\ &= [\Phi(z_{(n)} - \theta)]^n. \end{aligned}$$

Die Dichte ergibt sich über Differentiation bezüglich θ :

$$f_\theta(z_{(n)}) = n[\Phi(z_{(n)} - \theta)]^{n-1} \phi(z_{(n)} - \theta),$$

d.h. für zum Beispiel $n = 5$ und $z_{(n)} = x_3 = 3.5$ gilt

$$L_3(\theta) = 5[\Phi(3.5 - \theta)]^4 \phi(3.5 - \theta).$$

3.1 Parametrische Likelihood-Inferenz

Die gesamte Likelihood der drei Beobachtungen ist

$$L(\theta) = L_1(\theta) \cdot L_2(\theta) \cdot L_3(\theta),$$

also das Produkt der Likelihoodfunktionen L_1 , L_2 und L_3 .

Fazit: Die Likelihood ist sehr allgemein definiert.

3.1 Parametrische Likelihood-Inferenz

Beziehung zur Bayes-Inferenz

- ▶ $p(\theta)$ sei die Prioriverteilung,
- ▶ $f(x|\theta) = L(\theta)$ die Likelihood.
- ▶ Dann ist

$$p(\theta|x) \propto p(\theta) \cdot L(\theta)$$

„Posteriori“ \propto „Priori“ \times Likelihood.

3.1 Parametrische Likelihood-Inferenz

Likelihood-Quotient

Frage: Wie vergleicht man die Likelihoods $L(\theta_1)$ und $L(\theta_2)$ für $\theta_1 \neq \theta_2$?

Antwort: Man betrachtet den Quotienten (nicht die Differenz), da dieser invariant gegenüber eindeutigen Transformationen

$$x \mapsto y = y(x) \Leftrightarrow y \mapsto x(y)$$

ist. Für stetige x, y gilt mit dem Transformationssatz für Dichten:

$$f_Y(y|\theta) = f_X(x(y)|\theta) \left| \det \left(\frac{\partial x(y)}{\partial y} \right) \right|$$

und somit

$$L(\theta; y) = L(\theta; x) \left| \det \left(\frac{\partial x(y)}{\partial y} \right) \right| \Rightarrow \frac{L(\theta_2; y)}{L(\theta_1; y)} = \frac{L(\theta_2; x)}{L(\theta_1; x)}.$$

3.1 Parametrische Likelihood-Inferenz

Satz 3.2

1. Sei $T = T(X)$ suffizient für θ . Dann gilt
 $L(\theta; x) = \text{const} \times L(\theta; t)$ mit $t = T(x)$, d.h. $L(\theta; x)$ und $L(\theta; t)$ sind äquivalent.
2. $L(\theta; x)$ ist minimalsuffizient.

Beweis. Folgt unmittelbar aus den Resultaten aus Abschnitt 2. \square