

Angewandte Bayes-Statistik

Volker Schmid

LMU, Institut für Statistik

Sommersemester 2017

Zielsetzung

Für komplexere Modelle ist die Posteriori oft nicht mehr analytisch zugänglich. Insbesondere ist die Normalisierungskonstante, d.h., die marginale Likelihood

$$p(x) = \int f(x|\theta)p(\theta)d\theta$$

schwer zu berechnen. Auswege:

- ▶ Numerische Integration
- ▶ Approximation der Posteriori
- ▶ Simulationsverfahren

Simulationsbasierte Posteriori-Inferenz

Idee: Erzeuge Ziehungen aus der Posteriori-Verteilung und approximiere daraus Statistiken der Posteriori-Verteilung


- ▶ Posteriori-Erwartungswert durch den Mittelwert
- ▶ Posteriori-Median über Median der Stichprobe
- ▶ Quantile der Posteriori-Verteilung über Quantile der Stichprobe
- ▶ HPD-Intervalle als kürzeste Intervalle, die $100(1 - \alpha)\%$ der Stichprobe enthalten

Monte-Carlo-Integration

Definition 1 (Monte-Carlo-Integration).

Sei $f(x) > 0$ eine beliebige stetige Funktion mit bekanntem Wertebereich $[0, Y]$. $\int_a^b f(x)dx$ kann wie dann folgt approximiert werden.

- ▶ Ziehe n gleichverteilte Zufallszahlen x aus $[a, b]$
- ▶ Ziehe unabhängig davon n gleichverteilte Zufallszahlen y aus $[0, Y]$
- ▶ Berechne den Anteil h der Punkte (x_i, y_i) , die unterhalb der Funktion f liegen
- ▶ $\int_a^b f(x)dx \approx h(b - a)Y$



Monte-Carlo-Schätzer

Ist $p(x)$ eine Dichte, so können Integrale der Form

$$E(g(x)) = \int g(x)p(x)dx$$

mit einer Stichprobe x_1, \dots, x_m aus $p(x)$ durch den Stichprobenmittelwert

$$\bar{g}_m = \frac{1}{m} \sum_{i=1}^m g(x_i)$$

approximiert werden. Aus dem starken Gesetz der grossen Zahlen folgt

$$\lim_{m \rightarrow \infty} \frac{1}{m} \sum_{i=1}^m g(x_i) \rightarrow \int g(x)p(x)dx.$$

Monte-Carlo-Schätzer

Die Varianz des Monte-Carlo-Schätzers \bar{g}_m ist gegeben durch

$$\text{Var}(\bar{g}_m) = \frac{1}{m} \int (g(x) - E(g(x)))^2 p(x) dx = \frac{1}{m} \text{Var}(g).$$

Der Approximationsfehler verringert sich mit steigendem m . Es folgt sogar aus dem zentralen Grenzwertsatz

$$\sqrt{m}(g_m - E(g(x))) \sim N(0, \text{Var}(g)).$$

Schätzer für $\text{Var}(\bar{g}_m)$ ist

$$\widehat{\text{Var}}(\bar{g}_m) = \frac{1}{m-1} \sum_{i=1}^m (g(x_i) - \bar{g}_m)^2$$

Inversionsmethode

Gegeben sei die Verteilungsfunktion $F(x)$ einer Zufallsvariablen X .
Sei $u \sim U[0, 1]$. Dann ist

$$Y = F^{-1}(u) = \inf\{y : F(y) \geq u\} \sim X$$

Acceptance-Rejection-Methode

Ziel: Wir wollen aus einer Dichtefunktion $f(x)$ ziehen. Gegeben sei eine Dichtefunktion $g(x)$, nach der wir problemlos Zufallszahlen ziehen können. Es existiere ein c , so dass

$$cg(z) \geq f(z)$$

für alle z mit $f(z) > 0$. Dann können Zufallszahlen gemäß $f(x)$ wie folgt gezogen werden:

- ▶ ziehe Z gemäß $g(z)$
- ▶ akzeptiere Z mit Wahrscheinlichkeit $\frac{f(z)}{g(z)c}$

Squeezed Acceptance-Rejection-Sampling

Gegeben sei eine untere Schranke $s(z) \leq f(z)$. Für u Ziehung aus $U[0, 1]$ akzeptiere Z

- ▶ wenn $u \leq \frac{s(z)}{cg(z)}$
- ▶ wenn $u \leq \frac{f(z)}{cg(z)}$

Der zweite Schritt kann ausgelassen werden, wenn bereits im ersten Schritt akzeptiert wurde.

Markov Chain Monte Carlo

- ▶ Ziel: Ziehungen aus der Posterioriverteilung
- ▶ Simulationsbasierte Inferenz
- ▶ Funktioniert für komplexe und hochdimensionale Probleme
- ▶ Idee: Erzeuge eine Markovkette, deren stationäre Verteilung die Posterioriverteilung ist
- ▶ Ziehungen sind voneinander abhängig

Markov Chain Monte-Carlo-Methoden

Mit der Übergangsmatrix \mathbf{P} einer irreduziblen, aperiodischen Markovkette, deren stationäre Verteilung π ist, können Zufallszahlen $Y \sim \pi$ wie folgt erzeugt werden:

- ▶ Wahl eines beliebigen Startwerts $y^{(0)}$
- ▶ Simulation der Realisierungen einer Markovkette der Länge m mit Übergangsmatrix \mathbf{P} : $(y^{(1)}, \dots, y^{(m)})$

Ab einem gewissen Index b , dem *burn-in* geht der Einfluss der Startverteilung verloren und daher gilt approximativ

$$y^{(t)} \sim \pi, \text{ für } i = b, \dots, m.$$

Die Ziehungen sind identisch verteilt, aber nicht unabhängig.

Gibbs-Sampling

Beim Gibbs-Sampling zieht man abwechselnd aus den Full Conditional Posteriors (vollständig bedingte Posteriorverteilung) der einzelnen Parameter(blöcke).

Beispiel 1 (Normalverteilung).

Modell:

$$x_i \sim N(\mu, \sigma^2)$$

Likelihood:

$$p(\mathbf{x}|\mu, \sigma^2) = \left(\frac{1}{2\pi\sigma^2}\right)^{n/2} \exp\left(-\frac{1}{\sigma^2} \sum (x_i - \mu)^2\right)$$

Semi-konjugierte Prioris:

$$\begin{aligned}\mu &\sim N(m_0, s_0) \\ \tau = \sigma^{-2} &\sim Ga(a, b) \\ \mu &\perp \tau\end{aligned}$$

Posteriori-Verteilung:

$$p(\mu, \tau | \mathbf{x}) \propto \tau^{n/2} \exp\left(-\frac{\tau}{2} \sum (x_i - \mu)^2\right) \\ \cdot \exp\left(-\frac{1}{2s_0}(\mu - m_0)^2\right) \tau^a \exp(-b\tau)$$

Full conditional von μ :

$$p(\mu, | \mathbf{x}, \tau) \propto \exp\left(-\frac{\tau}{2} \sum (x_i - \mu)^2 - \frac{1}{2s_0}(\mu - m_0)^2\right)$$

Es handelt sich um den Kern der $N(s^{-1}m, s^{-1})$ -Verteilung mit $m = \tau \sum x_i + m_0/s_0$ und $s = n\tau + s_0^{-1}$.

Posteriori-Verteilung:

$$p(\mu, \tau | \mathbf{x}) \propto \tau^{n/2} \exp\left(-\frac{\tau}{2} \sum (x_i - \mu)^2\right) \\ \cdot \exp\left(-\frac{1}{2s_0}(\mu - m_0)^2\right) \tau^a \exp(-b\tau)$$

Full conditional von τ :

$$p(\tau | \mathbf{x}, \mu) \propto \tau^{a+n/2} \exp\left(-\left(b + 0.5 \sum (x_i - \mu)^2\right)\right)$$

Es handelt sich um den Kern der
 $Ga(a + n/2, b + 0.5 \sum (x_i - \mu)^2)$ -Verteilung.
Gibbs-Sampler:

1. Wähle Startwert τ_0
2. Ziehe $\mu \sim N(s^{-1}m, s^{-1})$
3. Ziehe $\tau \sim Ga(a + n/2, b + 0.5 \sum (x_i - \mu)^2)$
4. Iteriere 2 und 3 für $m = 1, \dots, M$

Metropolis-Hastings-Algorithmus

- ▶ Ziehe θ^* aus einer Vorschlagsverteilung (Proposal) mit Dichte $q(\theta|\theta^{(k-1)})$
- ▶ Akzeptiere θ^* wird mit Wahrscheinlichkeit

$$\alpha = \min \left(1, \frac{p(\theta^*|x)q(\theta^{(k-1)}|\theta^*)}{p(\theta^{(k-1)}|x)q(\theta^*|\theta^{(k-1)})} \right)$$

- ▶ Andernfalls setze $\theta^{(k)} = \theta^{(k-1)}$.

Vorschlagsdichten

- ▶ Independence Proposal: Vorschlagsverteilung ist unabhängig vom aktuellen Wert
- ▶ Symmetrisches Proposal: $q(\theta^*|\theta^{(k-1)}) = q(\theta^{(k-1)}|\theta^*)$, die Vorschlagsdichte kürzt sich aus der Akzeptanzwahrscheinlichkeit (Metropolis-Algorithmus):

$$\alpha = \frac{p(\theta^*|x)}{p(\theta^{k-1}|x)}$$

Jeder Vorschlag mit $p(\theta^*|x) > p(\theta^{k-1}|x)$ wird angenommen!

- ▶ Random Walk Proposal: Vorschlagsverteilung ist ein Random Walk

$$\theta^* = \theta^{(k-1)} + \epsilon, \epsilon \sim f$$

also $q(\theta^*|\theta^{(k-1)}) = f(\theta^* - \theta^{(k-1)})$.

Random Walk

Random Walk wird in der Regel mit Normalverteilung konstruiert:

$$\theta^* \sim N(\theta^{(k-1)}, C)$$

mit vorgegebener Kovarianzmatrix C .

- ▶ Eine zu kleine Varianz führt zu hohen Akzeptanzraten, aber ineffizienten, da stark autokorrelierten Ziehungen. Im Extremfall $C \rightarrow 0$ führt zu $\alpha = 1$, $\tau \rightarrow \infty$.
- ▶ Eine zu große Varianz führt zu zu großen Schritten, Vorschläge liegen in den Enden der Posterioriverteilung, sehr kleine Akzeptanzraten.
- ▶ Tuning der Kovarianzmatrix notwendig

Multivariate Verteilung

- ▶ Metropolis-Hastings-Algorithmus kann für θ -Vektoren durchgeführt werden
- ▶ Akzeptanzraten jedoch i.d.R. geringer mit höherer Dimension
- ▶ Alternative ist der komponentenweise Metropolis-Hastings: Jede Komponente des Parameters wird einzeln (skalar oder blockweise) aufdatiert. Sei $\theta = (\theta_1, \theta_2)$:

$$\alpha = \min \left(1, \frac{p(\theta_1^* | x, \theta_2^{(k-1)}) q(\theta_1^{(k-1)} | \theta^*, \theta_2^{(k-1)})}{p(\theta_1^{(k-1)} | x, \theta_2^{(k-1)}) q(\theta_1^* | \theta^{(k-1)}, \theta_2^{(k-1)})} \right)$$

- ▶ Updates können in fester oder zufälliger Weise erfolgen