

BZQ II: Stochastikpraktikum

Block 5: Markov-Chain-Monte-Carlo-Verfahren

Randolf Altmeyer

February 1, 2017

- 1 Monte-Carlo-Methoden, Zufallszahlen, statistische Tests
- 2 Nichtparametrische Methoden
- 3 Lineares Modell, Klassifikation, PCA
- 4 Simulation stochastischer Prozesse
- 5 **Markov-Chain-Monte-Carlo-Verfahren**

- 1 Rückblick: Simulation von Zufallszahlen
- 2 Ergodische Markovketten
- 3 Der Metropolis-Hastings-Algorithmus
- 4 Anwendungsbeispiel

Literatur:

- Christian Robert, George Casella: *Introducing Monte Carlo Methods with R*, 2010
- Christian Robert, George Casella: *Monte Carlo Statistical Methods*, 2004

- Simulation/Sampeln von Zufallsvariable X mit Dichte f

Anwendungen: Approximation von Erwartungswerten

$$\mathbb{E}[g(X)] \approx \frac{1}{n} \sum_{k=1}^n g(X_k)$$

- **Methoden aus Block 1:**

- Inversionsmethode (Inversion der Verteilungsfunktion)
- spezielle Methoden für Normalverteilung, diskrete Verteilungen
- Verwerfungsmethode

- **Gemeinsamkeiten dieser Methoden:**

- erzeugen *iid*-Samples
- basieren auf mehr oder weniger starken Annahmen (z.B. Existenz einer “guten” Kandidatendichte bei der Verwerfungsmethode)

- **Problem:** Annahmen sind häufig nicht erfüllt bzw. Kandidatendichten sind schwierig zu finden

Beispiel: (Bayes) A-Priori-Verteilung θ , “Daten” $X = (X_1, \dots, X_n)$ mit (bedingter) Dichte $f^{X|\theta}$

$$\Rightarrow \text{A-Posteriori-Dichte: } f^{\theta|X} = \frac{f^{\theta, X}}{f^X} = \frac{f^{X|\theta} f^\theta}{f^X} \propto f^{X|\theta} f^\theta$$

- **fundamentale Idee:**

- $(X_n)_{n \geq 0}$ sei eine Markovkette mit invarianter Verteilung μ (d.h. $\mathbb{P}_\mu(X_1 \in A) = \mu(A)$ für alle Borelmengen A)
- μ habe Lebesgue-Dichte f
- *Ergodensatz* (Birkhoff): Wenn $(X_n)_{n \geq 0}$ *ergodisch* ist, dann gilt für alle $g \in L^1(\mu)$, dass

$$\frac{1}{n} \sum_{k=0}^{n-1} g(X_k) \rightarrow \int g(x) f(x) dx = \mathbb{E}[g(X)], \quad n \rightarrow \infty.$$

- für “große” n erzeugt also die Markovkette annähernd Samples bezüglich f
- diese Samples sind *nicht* iid!
- *wie konstruiert man eine solche Markovkette?*

Der Metropolis-Hastings-Algorithmus

- **Algorithmus:**

- wähle X_0 beliebig/zufällig, so dass $f(X_0) > 0$
- angenommen wir haben X_n bereits erzeugt
- erzeuge $Y_n \sim q(\cdot | X_n)$
- sei $r(X_n, Y_n) = \min \left\{ 1, \frac{f(Y_n)q(X_n|Y_n)}{f(X_n)q(Y_n|X_n)} \right\}$ die *Akzeptanzwahrscheinlichkeit*
- setze

$$X_{n+1} = \begin{cases} Y_n & \text{mit Wahrscheinlichkeit } r(X_n, Y_n), \\ X_n & \text{mit Wahrscheinlichkeit } 1 - r(X_n, Y_n), \end{cases}$$

- das Ergebnis ist wirklich eine Markovkette!
- **Spezialfall:** $q(y|x) = q(x|y)$ ist symmetrisch (z.B. Gaussdichte)
 $\Rightarrow r(X_n, Y_n) = \min\{1, f(Y_n)/f(X_n)\}$

Interpretation:

- akzeptiere Y_n immer, wenn es in einem Bereich größerer Dichte liegt
- wenn Y_n in einem Bereich kleinerer Dichte liegt, dann vertrauen wir dem Sample weniger und "werfen eine Münze"

Eigenschaften von $(X_n)_{n \geq 0}$ (1)

- Übergangskern der Markovkette ist

$$\begin{aligned} K(x, A) &= \mathbb{P}(X_{n+1} \in A | X_n = x) \\ &= \int_A q(y|x) r(x, y) dy + \delta_x(A) \left(1 - \int q(y|x) r(x, y) dy\right), \end{aligned}$$

für Borelmenge A , d.h.

$$K(x, y) = q(y|x) r(x, y) + \delta_x(y) \left(1 - \int q(y|x) r(x, y) dy\right)$$

- Übergangskern erfüllt *detailed balance* bezüglich f , d.h. es gilt

$$K(y, x) f(y) = K(x, y) f(x) \text{ (nachrechnen!)}$$

\Rightarrow das Maß μ mit Dichte f ist invariante Verteilung von $(X_n)_{n \geq 0}$, da

$$\begin{aligned} \mathbb{P}_\mu(X_1 \in A) &= \int K(x, A) f(x) dx = \int K(x, y) f(x) \mathbf{1}_A(y) d(x, y) \\ &= \int K(y, x) f(y) \mathbf{1}_A(y) d(x, y) = \int f(y) \mathbf{1}_A(y) d(y) \\ &= \mu(A) \end{aligned}$$

Eigenschaften von $(X_n)_{n \geq 0}$ (2)

- wenn $q(y|x) > 0$ für alle $(x, y) \in \mathcal{E} \times \mathcal{E}$, wobei $\mathcal{E} = \text{supp}(f)$, dann ist $(X_n)_{n \geq 0}$ *irreduzibel*, d.h. jeder Punkt im Support \mathcal{E} von f kann in einem Schritt erreicht werden (denn $K(x, y) > 0$)
- man kann zeigen, dass $(X_n)_{n \geq 0}$ auch *aperiodisch* ist, wenn $\mathbb{P}(X_{n+1} = X_n) > 0$
- eine *aperiodische irreduzible* Markovkette ist *ergodisch*, d.h. Ergodensatz ist anwendbar für $(X_n)_{n \geq 0}$
- f bzw. $q(\cdot|x)$ müssen nur bis auf konstante Faktoren bekannt sein

Eigenschaften von $(X_n)_{n \geq 0}$ (3)

- es sollte leicht sein von $q(\cdot | x)$ zu sampeln
- erzeugte Samples hängen stark von Konvergenzgeschwindigkeit gegen die stationäre Verteilung ab
- Samples sind *nicht* unabhängig, Approximation erst nach Burn-in-Phase gut
- Vergleich mit der Verwerfungsmethode:
Accept-Reject (Verwerfungsmethode):
 - erzeuge $U \stackrel{d}{\sim} \text{Unif}([0, 1])$, $Y \stackrel{d}{\sim} g$ ($g =$ Kandidatendichte)
 - wenn $U \leq f(Y)/Mg(Y)$, dann *akzeptiere* $X := Y$
 - andernfalls *lehne* Y ab und kehre zum Anfang zurück

Welches q ?

- das beste q wäre $q = f \Rightarrow r(X_n, Y_n) = 1$

1. Methode: der unabhängige Metropolis-Hastings-Algorithmus

- $q(\cdot | x) \equiv q$
- $r(X_n, Y_n) = \min \left\{ 1, \frac{f(Y_n)q(X_n)}{f(X_n)q(Y_n)} \right\}$
- ähnlich zur Verwerfungsmethode, Bedingung $f/q \leq M$ muss nicht erfüllt sein

2. Methode: der random-walk Metropolis-Hastings-Algorithmus

- $Y_n = X_n + \epsilon_n$, ϵ_n iid mit Varianz σ^2 und symmetrisch mit Dichte q , so dass Y_n Dichte $q(\cdot - X_n)$ hat
- $q(-x) = q(x)$
- $r(X_n, Y_n) = \min \left\{ 1, \frac{f(Y_n)}{f(X_n)} \right\}$
- Verhalten hängt stark von σ^2 ab

Anwendungsbeispiel

- 28. Januar 1986: Explosion der Raumfähre Challenger aufgrund von Materialermüdungserscheinungen an Dichtungsringen
- Wahrscheinlicher Grund: ungewöhnlich niedrige Außentemperatur von 31 Grad Fahrenheit (ca. 0 Grad Celsius)

Materialprobleme	1	1	1	1	0	0	0	0	0	0	0	0
Temperatur (F)	53	57	58	63	66	67	67	67	68	69	70	70

Materialprobleme	1	1	0	0	0	1	0	0	0	0	0
Temperatur (F)	70	70	72	73	75	75	76	76	78	79	81

- **modelliere** Materialprobleme mit *logistischer Regression*:
 - Annahme: wir beobachten $Y_i \stackrel{iid}{\sim} \text{Ber}(p(x_i))$
 - x_i =Temperatur, Y_i =Materialproblem Ja/Nein
 - $p(x_i) = P(Y_i = 1 | X_i = x_i) = \frac{\exp(\alpha + x_i\beta)}{1 + \exp(\alpha + x_i\beta)}$, für Parameter $\alpha, \beta \in \mathbb{R}$
 - das ist ein *verallgemeinertes lineares Modell*
- **Ziel**: bestimme α, β anhand der Daten und mache Vorhersagen für ungesehene Temperaturen

- hier: Bayes-Analyse

- a-Priori-Verteilung: $\pi_\alpha(\alpha|b) = \frac{1}{b}e^\alpha e^{-e^\alpha/b}$, $\pi_\beta(\beta) = 1$, $b =$ Hyperparameter, weniger wichtig (für eine datengetriebene Wahl siehe Robert & Casella, 2004)

- Likelihood-Funktion:

$$L(\alpha, \beta | (x_i, y_i)_{i=1, \dots, 23}) = \prod_{i=1}^{23} p(x_i)^{y_i} (1 - p(x_i))^{1-y_i}$$

- a-Posteriori-Dichte: $f(\alpha, \beta) \propto L(\alpha, \beta | (x_i, y_i)_{i=1, \dots, 23}) \cdot \pi_\alpha(\alpha|b)$
- Vorschlagsdichte (unabhängig): $q(\alpha, \beta) = \pi_\alpha(\alpha|b)\phi(\beta)$, ϕ Dichte von $N(0, 1)$
- von q lässt sich leicht sampeln
- Akzeptanzwahrscheinlichkeit:

$$r((\alpha_n, \beta_n), (\tilde{\alpha}, \tilde{\beta})) = \min \left\{ 1, \frac{L(\tilde{\alpha}, \tilde{\alpha})\phi(\beta_n)}{L(\alpha_n, \beta_n)\phi(\tilde{\beta})} \right\}$$