

# Stochastik-Praktikum

## Markov Chain Monte Carlo-Methoden

Thorsten Dickhaus

Humboldt-Universität zu Berlin

14.10.2010



# Problemstellung

Wie kann eine Zufallsstichprobe am Computer simuliert werden, deren Verteilung aus einem komplizierten Bildungsgesetz (z. B. hierarchisch Bayes) herrührt?

## Definition

Eine Markov Chain Monte Carlo (MCMC)–Methode zur Simulation einer Wahrscheinlichkeitsverteilung mit Dichte  $f$  produziert eine **ergodische Markov-Kette**, welche die Verteilung mit Dichte  $f$  als stationäre Verteilung aufweist.

# Übersicht

- 1 Grundlegendes über Markov-Ketten
- 2 Der Metropolis-Hastings-Algorithmus
- 3 Anwendung auf das Logit-Modell
- 4 Der Gibbs-Sampler

Im Folgenden bezeichnet  $(\mathcal{X}, \mathcal{B}(\mathcal{X}))$  einen messbaren Raum.

### Definition

Ein Übergangskern ist eine Abbildung  $\mathcal{K} : \mathcal{X} \times \mathcal{B}(\mathcal{X}) \rightarrow \mathbb{R}$ , für die gilt:

- $\mathcal{K}(x, \cdot)$  ist ein Wahrscheinlichkeitsmaß auf  $\mathcal{B}(\mathcal{X}) \quad \forall x \in \mathcal{X}$
- $\mathcal{K}(\cdot, B)$  ist messbar  $\forall B \in \mathcal{B}(\mathcal{X})$

### Definition

Ein stochastischer Prozess in diskreter Zeit  $X_0, \dots, X_n, \dots$  heißt Markov-Kette (MC)  $(X_n)$  auf  $\mathcal{X}$ , falls  $\forall B \in \mathcal{B}(\mathcal{X})$

$$P(X_{k+1} \in B | x_0, \dots, x_k) = P(X_{k+1} \in B | x_k) = \int_B \mathcal{K}(x_k, dx)$$

für  $k \in \mathbb{N}$  mit einem Übergangskern  $\mathcal{K}$  gilt.

### Definition (Sei $\mathcal{X}$ abzählbar.)

- a) **Ersteintrittszeit** in  $x \in \mathcal{X}$ :

$$T^x := \min \{n > 0 \mid X_n = x\}, \quad f(x, y) := P_x(T^y < \infty) \quad x, y \in \mathcal{X}$$

- b)  $(X_n)$  heißt **zeithomogen**, falls  $\forall k \in \mathbb{N}$ :

$$P(X_{k+1} \in B \mid x_k) = P(X_1 \in B \mid x_0).$$

- c) Ein Zustand  $x \in \mathcal{X}$  heißt **rekurrent**, falls  $f(x, x) = 1$ .

Eine Markov-Kette  $(X_n)$  heißt rekurrent, falls jeder ihrer möglichen Zustände rekurrent ist. Ansonsten heißt  $(X_n)$  transient.

- d) Eine Markov-Kette heißt **irreduzibel**, falls jeder Zustand  $y$  von jedem Zustand  $x$  aus erreichbar ist.

## Satz

- 1 Falls MC  $(X_n)$  irreduzibel:  
Ein Zustand rekurrent  $\Leftrightarrow (X_n)$  rekurrent
- 2 Ist eine Markov-Kette **irreduzibel und rekurrent**, dann existiert ein **eindeutig bestimmtes invariantes Maß**  
 $\mu \equiv \mu_{\mathcal{K}}$ .  
Ist  $\mu$  endlich, heißt die Markov-Kette positiv-rekurrent.

## Korollar

MC irreduzibel und positiv-rekurrent, dann gilt:

$$\mathbb{E}[T^x] < \infty \text{ und } \mu(x) = (\mathbb{E}[T^x])^{-1}.$$

# Ergodizität

## Definition

**Periode:**  $d_x := \text{ggT}\{n \mid \mathcal{K}^n(x, x) > 0\}$

MC heißt **aperiodisch**, wenn  $d_x = 1 \forall x \in \mathcal{X}$ .

## Satz (Konvergenz ins Gleichgewicht)

Ist  $(X_n)$  eine irreduzible, positiv-rekurrenente, aperiodische (**ergodische**) Markov-Kette mit stationärer Verteilung  $\mu$ , so gilt für jede beliebige Startverteilung  $\mu_0$  von  $X_0$ :

$$\mu_0 \mathcal{K}^n \rightarrow \mu \text{ für } n \rightarrow \infty .$$

# Markov Chain Monte Carlo-Algorithmen

## Prinzip von MCMC-Algorithmen:

Für beliebige Startverteilungen wird eine ergodische Markov-Kette generiert.

Dabei wird der **Übergangskern** so gewählt, dass Konvergenz gegen eine festgelegte invariante Verteilung (**die Zielverteilung**) stattfindet.

## Anwendungsbeispiel:

Näherungsweise Berechnung von  $\int h(x)f(x)dx$  durch  $T^{-1} \sum_{i=n_0}^{n_0+T} h(X_i)$ , wobei  $f$  die stationäre Dichte ist und die sogenannte „burn-in-Phase“  $\{1, \dots, n_0 - 1\}$  ausgenommen wird.

# Übersicht

- 1 Grundlegendes über Markov-Ketten
- 2 Der Metropolis-Hastings-Algorithmus**
- 3 Anwendung auf das Logit-Modell
- 4 Der Gibbs-Sampler

Aufgabe: Simulation einer Stichprobe, die der Zielverteilung mit Dichte  $f$  folgt.

Gegeben sei  $X^{(t)} = x^{(t)}$ .

- 1 Generiere  $Y_t \sim q(y|x^{(t)})$  gemäß einer **proposal distribution  $q$** .
- 2 Acceptance-Rejection Schritt:

$$X^{(t+1)} = \begin{cases} Y_t & \text{mit Wahrscheinlichkeit } \rho(x^{(t)}, Y_t) \\ x^{(t)} & \text{mit Wahrscheinlichkeit } 1 - \rho(x^{(t)}, Y_t), \end{cases}$$

wobei

$$\rho(x, y) = \min \left( 1, \frac{f(y) q(x|y)}{f(x) q(y|x)} \right).$$

# Wahl der proposal distribution $q$

Metropolis-Hastings erzeugt eine irreduzible MC, falls

$$q(y|x) > 0 \quad \forall (x, y) \in \text{supp}(f) \times \text{supp}(f).$$

Aperiodizität gilt, falls

$$\mathbb{P} \left( f(X^{(t)})q(Y_t|X^{(t)}) \leq f(Y_t)q(X^{(t)}|Y_t) \right) < 1.$$

# Übergangskern des Metropolis-Hastings-Algorithmus'

Explizite Angabe von  $\mathcal{K}$ :

$$\mathcal{K}(x, y) = \rho(x, y)q(y|x) + \left(1 - \int \rho(x, y)q(y|x)dy\right) \delta_x(y).$$

Damit erfüllt  $(X_n)$  die **detailed balance**-Bedingung

$$\mathcal{K}(x, y)f(x) = \mathcal{K}(y, x)f(x) \quad \forall x, y.$$

## Satz

Besitzt eine Markov-Kette die „detailed balance“ Eigenschaft, so ist sie irreduzibel und  $f$  **Dichte der invarianten Verteilung**.

## Satz (Konvergenz von Metropolis-Hastings)

Ist die Metropolis-Hastings-Markov-Kette  $(X^{(t)})$   $f$ -irreduzibel, dann gilt




$$\lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T h(X^{(t)}) = \int h(x) f(x) dx \quad \forall h \in L^1(f), \quad f - \text{f. ü.}$$

Ist  $(X^{(t)})$  aperiodisch, so gilt außerdem

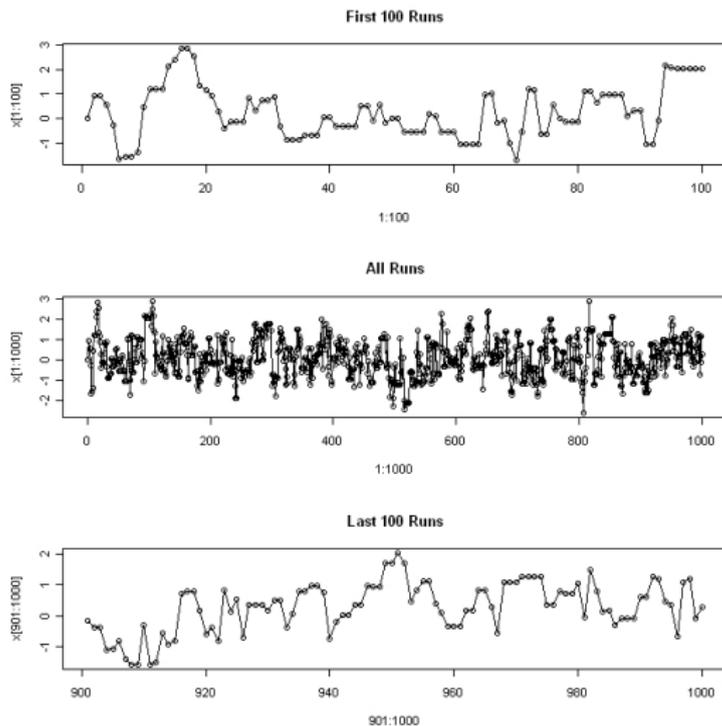
$$\lim_{n \rightarrow \infty} \left\| \int \mathcal{K}^n(x, \cdot) \mu(dx) - f \right\|_{TV} = 0$$

für jede Startverteilung  $\mu$ .

# Beispiel: Normalverteilung




# Beispiel: Normalverteilung




# Beispiel: Normalverteilung


first 100 qq-plot




next 100 qq-plot



last 100 qq-plot



qq-plot



# Übersicht

- 1 Grundlegendes über Markov-Ketten
- 2 Der Metropolis-Hastings-Algorithmus
- 3 Anwendung auf das Logit-Modell**
- 4 Der Gibbs-Sampler


# Challenger-Beispiel

Am 28. Januar 1986 explodierte die Raumfähre Challenger mit sieben Astronauten an Bord nach dem Start aufgrund von Materialermüdungserscheinungen an den O-Ringen.

Zum Startzeitpunkt herrschte eine ungewöhnlich niedrige Außentemperatur von  $31^{\circ}$  F (ca.  $0^{\circ}$  C).

Nachfolgend soll der Zusammenhang zwischen der Temperatur und der Überbeanspruchung der Dichtungsringe analysiert werden.

# Challenger-Beispiel



X	Y	X	Y
66	0	67	0
70	1	53	1
69	0	67	0
68	0	75	0
67	0	70	0
72	0	81	0
73	0	76	0
70	0	79	0
57	1	75	0
63	1	76	0
70	1	58	1
78	0		

# Logistische Regression

## Modell: Logistische Regression (Logit-Modell)

Sei  $Y$  binäre, Bernoulli-verteilte Zufallsvariable mit Parameter  $p(X)$  und  $X$  eine reellwertige Zufallsvariable:

$$\mathbb{P}(Y = 1) = p(X) = \frac{\exp(\alpha + X\beta)}{1 + \exp(\alpha + X\beta)} = 1 - \mathbb{P}(Y = 0).$$

Die **Logit-Funktion**  $\text{logit}(p) = \log(p/(1 - p)) = \alpha + X\beta$  hängt also linear von  $X$  ab.

# Logistische Regression

**Bayes-Ansatz** zur Schätzung der Parameter  $\alpha$  und  $\beta$ :

$$\begin{aligned} L(\alpha, \beta) &= \prod_{i=1}^{23} \mathbb{P}(Y_i = y_i | x_i) \\ &= \prod_i \left( \frac{\exp(\alpha + \beta x_i)}{1 + \exp(\alpha + \beta x_i)} \right)^{y_i} \left( \frac{1}{1 + \exp(\alpha + \beta x_i)} \right)^{1-y_i} \end{aligned}$$

mit **A priori-Verteilung**

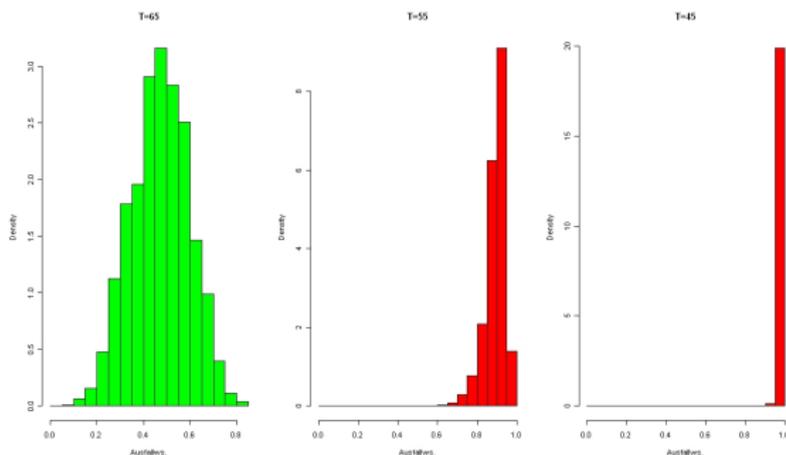
$$\pi(\alpha, \beta) = \pi_\alpha(\alpha | \beta) \pi_\beta(\beta).$$

**(Hierarchisches Bayes-Verfahren)**



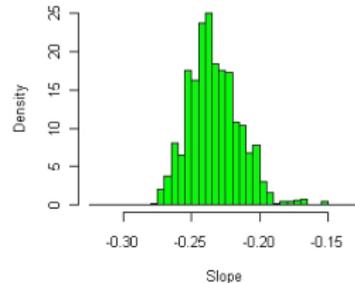
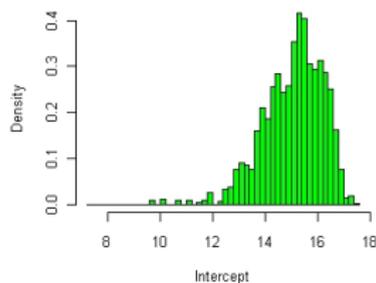
# Metropolis-Hastings im Logit-Modell

Um von der Zielverteilung (A posteriori-Verteilung) zu sampeln, wird nun ein Metropolis-Hastings-Algorithmus implementiert.

Resultierende Histogramme für die Ausfallwahrscheinlichkeit bei verschiedenen Temperaturen:



# Konvergenz Metropolis-Hastings



# Übersicht

- 1 Grundlegendes über Markov-Ketten
- 2 Der Metropolis-Hastings-Algorithmus
- 3 Anwendung auf das Logit-Modell
- 4 Der Gibbs-Sampler**

# Aufgabenstellung Gibbs-Sampler

$X = (X_1, \dots, X_p)^T$  ein  $\mathbb{R}^p$ -wertiger Zufallsvektor.

## Annahmen:

- 1 Weder von der gemeinsamen Verteilung mit Dichte  $f$  noch von den univariaten Randdichten  $f_1, \dots, f_p$  kann direkt simuliert werden.
- 2 Jedoch kann von den bedingten Verteilungen der

$$X_i | x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_p \sim f_i(x_i | x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_p)$$

gesamlet werden.

# Algorithmus: Gibbs-Sampler

Gegeben sei  $\mathbf{x}^{(t)} = (x_1^{(t)}, \dots, x_p^{(t)})$ . Generiere sukzessive

$$X_1^{(t+1)} \sim f_1(x_1 | x_2^{(t)}, \dots, x_p^{(t)}),$$

$$X_2^{(t+1)} \sim f_2(x_2 | x_1^{(t+1)}, x_2^{(t)}, \dots, x_p^{(t)}),$$

$$\vdots$$

$$X_p^{(t+1)} \sim f_p(x_p | x_1^{(t+1)}, \dots, x_{p-1}^{(t+1)}).$$

⇒ Zusammensetzung von  $p$  Metropolis-Hastings-Algorithmen mit Akzeptanzwahrscheinlichkeiten 1 und

$$q_i(\tilde{\mathbf{x}} | \mathbf{x}^{(t)}) = \delta_{(x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_p)} \\ \times (\tilde{x}_1, \dots, \tilde{x}_{i-1}, \tilde{x}_{i+1}, \dots, \tilde{x}_p) f_i(\tilde{x}_i | x_1^{(t)}, \dots, x_{i-1}^{(t)}, x_{i+1}^{(t)}, \dots, x_p^{(t)}).$$

## Satz (Konvergenz des Gibbs-Samplers)

Ist die vom Gibbs-Sampler erzeugte Markov-Kette  $(\mathbf{X}^{(t)})$  ergodisch, so ist  $f$  die Dichte der stationären Verteilung und es gilt für jede Startverteilung  $\mu$ :

$$\lim_{n \rightarrow \infty} \left\| \int \mathcal{K}^n(x, \cdot) \mu(dx) - f \right\|_{TV} = 0.$$

Ergodizität von  $(\mathbf{X}^{(t)})$  kann charakterisiert werden.

# Beispiel

Bivariate Normalverteilung:



$$(X, Y)^T \sim \mathbf{N} \left( \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix} \right).$$

*Die bedingten univariaten Verteilungen sind gegeben durch*


$$\mathcal{L}(X|Y=y) = \mathbf{N}(\rho y, (1-\rho^2)\sigma_1^2),$$

$$\mathcal{L}(Y|X=x) = \mathbf{N}(\rho x, (1-\rho^2)\sigma_2^2).$$


# R-Code: Gibbs-Sampler bivariate Normalverteilung





Histogram of  $bvn[, 1]$




Histogram of  $bvn[, 2]$



# R-Code: Gibbs-Sampler bivariate Normalverteilung



Histogram of  $bvn[, 1]$



Histogram of  $bvn[, 2]$

