
Seminar Stochastische Geometrie und räumliche Statistik, SS 2002

Endliche Markov Ketten und Monte-Carlo-Simulation

- 1 – Einleitung
- 2 – MCMC-Methode
- 3 – Literatur



1 Einleitung

1.1 Monte-Carlo-Methode

- 1949, J.v.Neumann und S.Ulam
- theor. Grundlagen schon lange vorher bekannt
- breite Anwendung erst mit dem Einsatz von DV-Anlagen in den 90-er Jahre(Bildanalyse, -verarbeitung)
- Monte-Carlo, Monaco; Spielkasino, Roulette
- universelle Methode, weil sie viele Vorgänge nachzubilden vermag, auf deren Ablauf zufällige Faktoren Einfluß nehmen

1.2 Markov-Ketten

Definition 1

Sei (Ω, \mathcal{F}, P) ein Wahrscheinlichkeitsraum, I eine beliebige nicht leere Indexmenge und (S, \mathcal{S}) ein meßb. Raum. Eine Familie $\{X_i, i \in I\}$ von Zufallsvariablen mit Werten in S heißt *stochastischer Prozeß* mit Parameterbereich I und Zustandsraum S .

Definition 2

Eine *Markov-Kette* ist ein stochastischer Prozeß $\{X_n, n \in I := \mathbb{Z}^+\}$ mit abzähl. Zustandsraum S , der die folg. Markovsche Eigenschaft

besitzt: $\forall n, i_0, \dots, i_{n-1}, i, j \in \mathbb{Z}^+$ und $\forall s_{i_0}, \dots, s_{i_{n-1}}, s_i, s_j \in S$ mit

$P(X_0 = s_{i_0}, \dots, X_n = s_{i_n}) > 0$ ist

$$P(X_{n+1} = s_j \mid X_0 = s_{i_0}, \dots, X_{n-1} = s_{i_{n-1}}, X_n = s_i)$$

$$= P(X_{n+1} = s_j \mid X_n = s_i)$$

$$= p_{ij}.$$

Mit $p_{ij} \geq 0$ und $\sum_{j \in I} p_{ij} = 1 \forall i \in I$.

Bemerkung 1 *Wir betrachten hier nur den endl. Zustandsraum*

$$S = \{s_1, \dots, s_k\}.$$

Definition 3

- (a) Eine MK heißt *homogen* oder Kette mit *stationären Übergangswahrscheinlichkeiten* p_{ij} , wenn $\forall i, j \in I$
 $p_{ij} := P(X_{n+1} = s_j \mid X_n = s_i)$ unabh. von n ist.
- (b) $p_{ij}^{(m)} := P(X_{n+m} = s_j \mid X_n = s_i)$ ist die *m-Schritt Übergangswahrscheinlichkeit*.
- (c) Eine WFkt $\alpha = (\alpha_i, i \in I)$ mit $\alpha_i = P(X_0 = s_i)$ heißt *Start-/Anfangsverteilung*.
- (d) Anfangsverteilung heißt *stationär*, wenn $\alpha^T = \alpha^T \mathbf{P}$, d.h.
 $\forall j \in I \quad \alpha_j = \sum_{i \in I} \alpha_i p_{ij}$ gilt, wobei \mathbf{P} die Übergangsmatrix ist.

Definition 4

- (a) $s_i \rightarrow s_j[n]$ heißt der Zustand s_i führt in n Schritten zum Zustand s_j , wenn $p_{ij}^{(n)} > 0$.
- (b) Gibt es ein $n \geq 1$, mit $s_i \rightarrow s_j[n]$, so sagen wir s_i führt zu s_j und schreiben $s_i \rightarrow s_j$.
- (c) $s_i \leftrightarrow s_j$ bedeutet s_i *kommuniziert* mit s_j .
- (d) s_i heißt *wesentlich*, wenn jeder Zustand s_j , zu dem s_i führt, auch zu s_i führt.

Definition 5

MK $\{X_n\}$ oder ihre Übergangsmatrix $\mathbf{P} = (p_{ij})$ heißt *irreduzibel*, wenn S nur aus einer Klasse besteht, d.h. $s_i \leftrightarrow s_j \forall s_i, s_j \in S$.

Definition 6

- (a) Für einen Zustand s_i mit $s_i \rightarrow s_i$ heißt der ggT der potenziellen Rückkehrzeiten $d(s_i) = \text{ggT}\{n \geq 1 : s_i \rightarrow s_i[n]\}$ die *Periode* von s_i .
- (b) Gilt nicht $s_i \rightarrow s_i$, so sei $d(s_i) = \infty$.
- (c) Zustände mit $d(s_i) = 1$ heißen *aperiodisch*.
- (d) Die Kette heißt *aperiodisch*, wenn alle Zustände aperiodisch sind, und *periodisch* mit Periode d , wenn alle $d(s_i) = d \geq 2$ sind.

1.3 Ergodizität

Definition 7

Ein Zustand s_i heißt *rekurrent*, wenn

$P(X_n = s_i \text{ für } \infty - \text{viele } n \mid X_0 = s_i) = 1$ gilt, sonst *transient*.

MK heißt rekurrent(transient), wenn jeder Zustand rekurrent(transient) ist.

Definition 8

Eine MK $\{X_n\}$ mit Übergangsmatrix $\mathbf{P} = (p_{ij})$ heißt *ergodisch*, wenn

- (a) $\forall j \in I : \pi_j := \lim_{n \rightarrow \infty} p_{ij}^{(n)}$ ex.,
- (b) $\pi_j \geq 0$ und von i unabh.,
- (c) (π_j) ist WFunktion, d.h. $\sum_{j \in I} \pi_j = 1$.

Theorem 1 *Eine MK $\{X_n\}$ mit Übergangsmatrix $\mathbf{P} = (p_{ij})$ ist ergodisch $\Leftrightarrow \mathbf{P} = (p_{ij})$ regulär ist (d.h. $\exists n_0 \geq 1$, so daß alle $p_{ij}^{(n_0)} > 0$ sind).*

Beweis: (s. Literatur (4))

Theorem 2 Sei $\{X_n\}$ ergodische MK, dann ist $\pi = (\pi_1, \dots, \pi_k)$ die eindeutige WLösung von $\pi_j = \sum_{i \in I} \pi_i p_{ij}, \forall j \in I$.

Beweis: (s. Literatur (4))

Theorem 3 Sei $\{X_n\}$ eine MK mit endl. Zustandsraum. Dann gilt: MK ist ergodisch \Leftrightarrow MK irreduzibel und aperiodisch ist.

Beweis: (s. Literatur (4))

Definition 9

Sei $\{X_n\}$ eine MK mit einem Zustandsraum $S = \{s_1, \dots, s_k\}$ und Übergangsmatrix $\mathbf{P} = (p_{ij})$. Die Anfangsverteilung α heißt *reversibel*, wenn $\forall i, j \in I$ gilt $\alpha_i p_{ij} = \alpha_j p_{ji}$.

Eine MK heißt reversibel, wenn sie eine reversible Anfangsverteilung besitzt.

Theorem 4 *Sei $\{X_n\}$ eine MK mit dem Zustandsraum $S = \{s_1, \dots, s_k\}$ und Übergangsmatrix \mathbf{P} . Wenn die Anfangsverteilung der Kette α reversibel ist, dann ist sie auch stationär.*

Beweis: (s. Literatur(2))

2 MCMC-Methode

2.1 Problemstellung

Gegeben ist eine Verteilung π auf dem Zustandsraum $S = \{s_1, \dots, s_k\}$.

Frage: Wie generiert man eine Zufallsvariable X mit der Verteilung π ?

2.2 Beispiel: Das hard-core-Modell

$G = (V, E)$ - Graph mit einer Menge der Pixel V und einer Menge der Kanten E . Den Pixeln wird zuf. der Wert 0 bzw. 1 zugewiesen, so daß 2 benachbarte Pixel nicht gleichzeitig den Wert 1 annehmen können. Konfigurationen aus der Menge $\{0, 1\}^V$, die dieses erfüllen, nennen wir *zulässig*.

μ_G - WMaß auf $\{0, 1\}^V$, so daß für $\xi \in \{0, 1\}^V$ mit $Z_G := \{\# \text{ der zulässigen Konfigurationen}\}$ gilt:

$$(\pi_\xi) = \mu_G(\xi) = \begin{cases} \frac{1}{Z_G} & \text{für } \xi \text{ zulässig} \\ 0 & \text{sonst} \end{cases}$$

$n(\xi) := \{\# \text{ von "1" in } \xi\}$,

X - zuf. Konfig. mit Vert. μ_G ,

$$\mathbb{E}[n(X)] = \sum_{\xi \in \{0,1\}^V} n(\xi) \mu_G(\xi) = \frac{1}{Z_G} \sum_{\xi \in \{0,1\}^V} n(\xi) 1_{\{\xi \text{ zulässig}\}} = ?$$

2.3 Ausweg: Simulation

- Generierung von ZV $X_i \sim \mu_G$ mit $i \in \{1, \dots, N\}$

- $\hat{n} = \sum_{i=1}^N \frac{n(X_i)}{N} \rightarrow \mathbb{E}[n(X)] \quad f.s. \quad \text{für } N \rightarrow \infty \quad (\text{SGGZ})$

2.4 Erster Versuch(allg.):

$X := \psi(U)$, mit $U \sim U [0, 1]$ und $\psi : [0, 1] \rightarrow S$

$$\psi(x) = \begin{cases} s_1 & \text{für } x \in [0, \pi_{s_1}) \\ \vdots & \\ s_i & \text{für } x \in \left[\sum_{j=1}^{i-1} \pi_{s_j}, \sum_{j=1}^i \pi_{s_j} \right) \\ \vdots & \\ s_k & \text{für } x \in \left[\sum_{j=1}^{k-1} \pi_{s_j}, 1 \right] \end{cases}$$

$\Rightarrow X \sim \pi$

2.5 Verbesserung: MCMC-Methode

Idee:

Wir konstruieren eine MK (X_0, X_1, \dots) auf einem WRaum (Ω, \mathcal{F}, P) mit Zustandsraum $S = \{s_1, \dots, s_k\}$. Die Kette soll:

- irreduzibel und aperiodisch sein
- und deren stationäre Verteilung soll die gewünschte Verteilung π sein.

2.6 Beispiel: s.o.

$V = \{v_1, \dots, v_k\}$, $S = \{\xi \in \{0, 1\}^V : \xi \text{ ist zulässig}\}$, μ_G .

Für die Konstruktion der MK benötigen wir den folg.

Übergangsmechanismus: zu jedem Zeitpunkt $(n + 1) \in \mathbb{N}$:

1. Generiere $v \in V$ (gleichvert.)
2. Werfe eine faire Münze(Bernoulli)
3. (Kopf) \wedge (alle Nachbarn von $v=0$): $X_{n+1}(v) := 1$
4. Sonst: $X_{n+1}(v) := 0$
5. $\forall w \in V \setminus \{v\} : X_{n+1}(w) := X_n(w)$

Diese MK ist irreduzibel und aperiodisch, μ_G ist die stat. Anfangsverteilung dieser Kette.

Beweis der Stationarität:

Sei $\xi, \xi' \in S$. Mit Theorem 4 noch z.z.: μ_G ist reversibel, d.h.

$$\mu_G(\xi)p_{\xi\xi'} = \mu_G(\xi')p_{\xi'\xi}.$$

$d := d(\xi, \xi') = \{ \# \text{ von Pixeln, in denen } \xi \text{ und } \xi' \text{ sich unterscheiden} \}.$

Fall 1: $d = 0$: $\xi = \xi'$.

Fall 2: $d \geq 2$: $\mu_G(\xi)p_{\xi\xi'} = \mu_G(\xi')p_{\xi'\xi} = 0$.

Fall 3: $d = 1$: $\mu_G(\xi)p_{\xi\xi'} = \frac{1}{Z_G} \frac{1}{2k} = \mu_G(\xi')p_{\xi'\xi}$. □

Der obige Algorithmus ist ein typischer MCMC-Algorithmus

- i) erfüllt sogar die strengere Eigenschaft: die Reversibilität,
- ii) gehört in eine spezielle Klasse der MCMC-Algorithmen: *Gibbs Sampler*.

2.7 Hastings-Metropolis-Algorithmus:

Wir generieren eine MK mit einer stationären Verteilung π . Sei $\pi_j = \frac{b(j)}{B}$

mit $b(j) \geq 0$, $j = 1, \dots, k$, k groß und $B = \sum_{j=1}^k b_j < \infty$ und sei

$Q = (q_{ij})$ eine irreduzible Übergangsmatrix.

Für die Konstruktion der MK benötigen wir folg.

Übergangsmechanismus: zu jedem Zeitpunkt $(n + 1) \in \mathbb{N}$ mit $X_n = i$:

1. Generiere eine ZVar. Z mit

$$P(Z = j) = q_{ij}, j = 1, \dots, k$$

2. Wenn $Z = j$, dann

$$X_{n+1} := \begin{cases} j & \text{mit W. } \phi_{ij} \\ i & \text{mit W. } (1 - \phi_{ij}) \end{cases}$$

Diese MK hat \mathbf{P} als Übergangsmatrix mit $p_{ij} = q_{ij}\phi_{ij}$, wenn $j \neq i$

$$p_{ii} = 1 - \sum_{m \neq i} q_{im}\phi_{im}.$$

Diese MK ist reversibel und damit stat., falls ϕ_{ij} wie folgt gewählt werden:

$$\phi_{ij} = \min \left\{ \frac{\pi_j q_{ji}}{\pi_i q_{ij}}, 1 \right\} = \min \left\{ \frac{b_j q_{ji}}{b_i q_{ij}}, 1 \right\}.$$

π ist die stat. Verteilung der Kette.

Beweis der Stationarität:

Mit Theorem 4 noch z.z.:

$$\pi_i p_{ij} = \pi_j p_{ji} \quad \forall j \neq i$$
$$\Leftrightarrow \pi_i q_{ij} \phi_{ij} = \pi_j q_{ji} \phi_{ji} \quad (*).$$

(*) ist erfüllt.

Denn wenn $\phi_{ij} = \frac{\pi_j q_{ji}}{\pi_i q_{ij}}$ ist, dann ist $\phi_{ji} = 1$ und umgekehrt. □

$\phi_{ij} = \min \left\{ \frac{b^{(j)} q_{ji}}{b^{(i)} q_{ij}}, 1 \right\}$ ist jetzt von B unabh. und π_j ist gleichzeitig auch die Grenzverteilung (wenn $p_{ii} > 0 \forall i$).

2.8 Eine Version des HM-Algorithmus:

Sei $\pi = (\pi_1, \dots, \pi_k)$ WVerteilung auf $S = (s_1, \dots, s_k)$.

- Konstruiere G (Graph) mit Pixeln aus S und einer bel. Menge E , die jedoch folgende Kriterien erfüllen sollte:
 - die hervorg. Kette ist irreduzibel,
 - jedes Pixel sollte nicht der Endpkt. von zu vielen Kanten sein .
- $d_i := \{ \# \text{ von Nachb. von } s_i \}$ und $s_j \sim s_i$ heißt: s_j ist Nachb. von s_i . \mathbf{P} ist die Übergangsmatrix mit

$$p_{ij} = \begin{cases} \frac{1}{d_i} \min \left\{ \frac{\pi_j d_i}{\pi_i d_j}, 1 \right\} & \text{wenn } s_i \sim s_j \\ 0 & \text{wenn } s_i \not\sim s_j \\ 1 - \sum_{l, s_l \sim s_i} \frac{1}{d_i} \min \left\{ \frac{\pi_l d_i}{\pi_i d_l}, 1 \right\} & \text{wenn } s_i = s_j \end{cases}$$

- Übergangsmechanismus: zu jedem Zeitpunkt $(n + 1) \in \mathbb{N}$ mit $X_n = s_i$:

1. Generiere s_j (gleichvert. auf der Menge der Nachb. von s_i)
2. $X_{n+1} := \begin{cases} s_j & \text{mit W. } \min \left\{ \frac{\pi_j d_i}{\pi_i d_j}, 1 \right\} \\ s_i & \text{mit W. } \left(1 - \min \left\{ \frac{\pi_j d_i}{\pi_i d_j}, 1 \right\} \right) \end{cases}$

Diese MK besitzt die stat. Verteilung π .

2.9 Gibbs-Sampler:

Die meistgenutzte Version des HM-Algorithmus ist der Gibbs-Sampler.

Sei $\mathbf{X} = (X(1), \dots, X(k))$ ein ZVektor mit WFkt $p(\mathbf{x})$.

Wir wollen einen ZVektor \mathbf{X} generieren mit WFkt

$$\pi_{\mathbf{x}} = \frac{p(\mathbf{x})}{P(\mathbf{X} \in \mathcal{A})} \quad \forall \mathbf{x} \in \mathcal{A}.$$

Ann: für $i, i = 1, \dots, k$ und die Werte $x_j, j \neq i$, können wir eine ZVar.

Z generieren mit W .

$$P(Z = z) = P(X(i) = z | X(j) = x_j, j \neq i) = \frac{p(\mathbf{y})}{\sum_{\mathbf{x} \in \mathcal{A}, X(j)=x_j, j \neq i} p(\mathbf{x})} \quad (**)$$

mit $\mathbf{y} = (x_1, \dots, x_{i-1}, z, x_{i+1}, \dots, x_k)$ und

$\mathbf{x} = (x_1, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_k)$.

Gibbs-Sampler ist eine MK, die zum Zeitpunkt $(n + 1) \in \mathbb{N}$ folg. Anweisungen folgt mit $\mathbf{X}_n = \mathbf{x} = (x_1, \dots, x_i, \dots, x_k) \in \mathcal{A}$:

1. Generiere eine Koord. i (gleichv.)
2. $\forall j \neq i : X_{n+1}(j) := x_j$
3. Generiere eine ZVar. Z mit W. (**)
4. Wenn $Z = z$, dann ist

$\mathbf{y} = (x_1, \dots, x_{i-1}, z, x_{i+1}, \dots, x_k)$ und

$$X_{n+1} := \begin{cases} \mathbf{y} & \text{mit W. } \phi_{\mathbf{x}\mathbf{y}} \\ \mathbf{x} & \text{mit W. } (1 - \phi_{\mathbf{x}\mathbf{y}}) \end{cases}$$

wobei $\phi_{\mathbf{x}\mathbf{y}} = \min \left\{ \frac{\pi_{\mathbf{y}} q_{\mathbf{y}\mathbf{x}}}{\pi_{\mathbf{x}} q_{\mathbf{x}\mathbf{y}}}, 1 \right\}$ und $q_{\mathbf{x}\mathbf{y}} = \frac{1}{k} \frac{p(\mathbf{y})}{\sum_{\mathbf{x} \in \mathcal{A}, X(j)=x_j, j \neq i} p(\mathbf{x})}$.

Für $\mathbf{x} \in \mathcal{A}$ und $\mathbf{y} \in \mathcal{A}$ gilt:

$$\frac{\pi_{\mathbf{y}} q_{\mathbf{y}\mathbf{x}}}{\pi_{\mathbf{x}} q_{\mathbf{x}\mathbf{y}}} = \frac{\pi_{\mathbf{y}} p(\mathbf{x})}{\pi_{\mathbf{x}} p(\mathbf{y})} = 1$$

und für $\mathbf{x} \in \mathcal{A}$ und $\mathbf{y} \notin \mathcal{A}$ (da $\pi_{\mathbf{y}} = 0$):

$$\frac{\pi_{\mathbf{y}} q_{\mathbf{y}\mathbf{x}}}{\pi_{\mathbf{x}} q_{\mathbf{x}\mathbf{y}}} = 0.$$

$\pi_{\mathbf{x}}$ ist die stat. Grenzverteilung dieser MK.

2.10 Beispiel: ein MCMC-Algorithmus für q -Colourings

Sei $G = (V, E)$, $q \geq 4$, ganzzahlig.

Zuweisung von q versch. Farben/Werten, so dass 2 benachbarte Pixel versch. Farben besitzen.

Zuf. q -Colouring bedeutet, daß ein q -Colouring auf der Menge der für G zulässigen q -Colourings generiert wird (gleichvert).

p_G - W-Maß auf $\{1, \dots, q\}^V$.

Ein Gibbs-Sampler für zuf. q -Colouring ist eine MK, die zu jedem Zeitpunkt $(n + 1) \in \mathbb{N}$ folg. Vorschriften folgt:

1. Generiere $v \in V$ (gleichvert.)
2. Generiere eine Farbe für $X_{n+1}(v)$ (gleichvert. auf der Menge der für v zul. Farben)
3. $\forall w \in V \setminus \{v\}: X_{n+1}(w) := X_n(w)$

Diese Kette ist aperiodisch und hat die stat. Verteilung p_G .

2.11 Eine Gibbs-Sampler-Variante:

Anstatt v zuf. zu ermitteln, können wir uns system. durch V bewegen.
 Wenn $V = \{v_1, \dots, v_k\}$, dann entscheiden wir uns für das Pixel

$$\left\{ \begin{array}{l} v_1 \quad \text{zum Zeitpunkt } 1, k + 1, \dots \\ \vdots \\ v_i \quad \text{zum Zeitpunkt } i, k + i, \dots \\ \vdots \\ v_k \quad \text{zum Zeitpunkt } k, 2k, \dots \end{array} \right.$$

Diese MK ist aperiodisch und besitzt gewünschte reversible Verteilung.
 Sie ist irreduzibel, wenn das ursprüngliche „zuf.-Punkte-Gibbs-Sampler“
 irreduzibel ist.

3 Literatur

- (1) P.Brémaud(1998): Markov Chains: Gibbs Fields, Monte Carlo Simulation and Queues, Springer.
- (2) O.Häggström(2001): Finite Markov chains and Algorithmic Applications,
<http://dimacs.rutgers.edu/~dbwilson/exact.html#haggstrom:course>
- (3) U.Krengel(1998): Einführung in die Wahrscheinlichkeitstheorie und Statistik, Vieweg.
- (4) T.Rolski, H.Schmidli, V.Schmidt, J.Teugels(1999): Stochastic Processes for Insurance and Finance, John Wiley & Sons Ltd.

- (5) S.M.Ross(1997): Introduction to Probability Models, Academic Press.
- (6) J.M.Sobol(1991): Die Monte-Carlo-Methode, Deutscher Verlag der Wissenschaften Berlin.