

---

# Perfekte Simulation unter Laufzeitbeschränkung

---

# Inhaltsverzeichnis

<b>1</b>	<b>Markov-Ketten</b>	<b>3</b>
<b>2</b>	<b>Markov-Chain-Monte-Carlo-Simulation (MCMC)</b>	<b>11</b>
<b>3</b>	<b>Propp-Wilson, Coupling-From-The-Past (CFTP)</b>	<b>16</b>
3.1	Wiederholung und Spezialfälle . . . . .	17
3.2	Abhängigkeit des Outputs von der Laufzeit . . . . .	21
<b>4</b>	<b>Der Fill-Algorithmus</b>	<b>24</b>
4.1	Einführung . . . . .	25

---

4.2	Begründung . . . . .	28
<b>5</b>	<b>Beispiel: Das Ising-Modell</b>	<b>37</b>
5.1	Modellbeschreibung . . . . .	38
5.2	Implementierung mit CFTP . . . . .	43
5.3	Implementierung mit Fill . . . . .	44
<b>6</b>	<b>Vergleich</b>	<b>48</b>

# 1 Markov-Ketten

## Definition 1.1

- $(\Omega, \mathcal{F}, \mathbb{P})$  sei Wkt.-Raum und  $E := \{1, \dots, l\}$  Zustandsraum ( $l \in \mathbb{N}$ ).
- $X_0, X_1, \dots : \Omega \rightarrow E$  heißt Markov-Kette  $:\Leftrightarrow$   
$$\mathbb{P}(X_n = i_n | X_{n-1} = i_{n-1}, \dots, X_0 = i_0) = \mathbb{P}(X_n = i_n | X_{n-1} = i_{n-1}) \quad \forall n \in \mathbb{N}, \quad \forall i_k \in E, \quad k = 1, \dots, n \text{ und falls}$$
$$\mathbb{P}(X_{n-1} = i_{n-1}, \dots, X_0 = i_0) > 0$$
- $P \in \mathbb{R}^{l \times l}$  mit  $p_{ij} = \mathbb{P}(X_n = j | X_{n-1} = i)$  heißt Übergangsmatrix der Markov-Kette  $(X_n)_{n \in \mathbb{N}}$

## Theorem 1.2 (Konstruktion von Markov-Ketten)

Für jede Markov-Kette existiert eine rekursive Darstellung, d.h. die  $X_n$  sind gegeben durch:

$X_0$  bel.

$$X_n = \Phi(X_{n-1}, Z_n) \quad \forall n \in \mathbb{N}$$

wobei  $Z_1, Z_2, \dots : \Omega \rightarrow D$  iid. und  $X_0$  unabhängig von  $Z_1, Z_2, \dots$

$\Phi : E \times D \rightarrow E$  heißt Updatefunktion.

Weiter gilt für die Übergangsmatrix  $P = (p_{ij})$ :

$$p_{ij} = \mathbb{P}(\Phi(i, Z_n) = j)$$

### Beispiel 1.3 (Random Walk)

$Z_1, Z_2, \dots : \Omega \rightarrow \{-1, 1\}$  seien iid ZV. Setze  $X_0 := 0$ ,

$X_n := X_{n-1} + Z_n \quad \forall n \in \mathbb{N}$ . Theorem 1.2  $\Rightarrow (X_n)$  ist eine MK mit ÜM

$P$ , wobei

$$\begin{aligned} p_{ij} &= \mathbb{P}(\Phi(i, Z_n) = j) = \mathbb{P}(i + Z_1 = j) = \mathbb{P}(Z_1 = j - i) \\ &= \begin{cases} 0.5 & j = i - 1 \\ 0.5 & j = i + 1 \\ 0 & \text{sonst} \end{cases} \end{aligned}$$

### Definition 1.4

$P^{(n)} = (p_{ij})^{(n)} \in \mathbb{R}^{l \times l}$  mit  $p_{ij}^{(n)} = \mathbb{P}(X_n = j | X_0 = i)$  heißt die  $n$ -stufige Übergangsmatrix der MK  $(X_n)_{n \in \mathbb{N}_0}$ .

### Definition 1.5

- Eine Markov-Kette  $(X_n)_{n \in \mathbb{N}_0}$  heißt **ergodisch**  $:\Leftrightarrow$   
Die Grenzwerte  $\pi_j = \lim_n p_{ij}^{(n)} \quad \forall j \in E$  existieren, sind positiv, hängen nicht von  $i \in E$  ab und bilden eine Wahrscheinlichkeitsfunktion.
- $\pi = (\pi_1, \dots, \pi_l)^\top$  heißt **Grenzverteilung** von  $(X_n)_{n \in \mathbb{N}_0}$ .

## Theorem 1.6

Sei  $(X_n)_{n \in \mathbb{N}_0}$  eine ergodische Markov-Kette.

$\Rightarrow \pi$  ist die Wahrscheinlichkeitsfunktion, die das LGS

$$\pi^\top = \pi^\top P$$

eindeutig löst.

Später interessieren wir uns für MK  $(\tilde{X}_n)_{n \in \mathbb{N}}$ , bei denen die "Zeitachse" umgedreht wird, d.h. es gilt:

$$\mathbb{P}(X_0 = i_0, X_1 = i_1, \dots, X_n = i_n) = \mathbb{P}(\tilde{X}_n = i_0, \tilde{X}_{n-1} = i_1, \dots, \tilde{X}_0 = i_n)$$

### Definition 1.7

Sei  $(X_n)_{n \in \mathbb{N}_0}$  eine ergodische MK mit ÜM  $P = (p_{ij})$  und stationärer Grenzverteilung  $\pi = (\pi_1, \dots, \pi_l)^\top$ . Dann heißt die (ergodische) MK  $(\tilde{X}_n)_{n \in \mathbb{N}}$  mit ÜM  $\tilde{P} = (\tilde{p}_{ij})$  gegeben durch

$$\tilde{p}_{ij} = \frac{\pi_j}{\pi_i} p_{ji}$$

die zeitinverse MK von  $X$ .

### Definition 1.8

Gilt  $P = \tilde{P}$ , dann heißt die MK  $(X_n)_{n \in \mathbb{N}_0} = (\tilde{X}_n)_{n \in \mathbb{N}_0}$  reversibel.

## Beispiel 1.9

Übergangsmatrix der MK  $(X_n)$ :

$$P = \begin{pmatrix} 0.5 & 0.5 & 0 \\ 0 & 0 & 1 \\ 0.5 & 0 & 0.5 \end{pmatrix}$$

$\Rightarrow \pi = (0.4, 0.2, 0.4)^\top$  und von  $\tilde{X}_n$ :

$$\tilde{P} = \begin{pmatrix} 0.5 & 0 & 0.5 \\ 1 & 0 & 0 \\ 0 & 0.5 & 0.5 \end{pmatrix}$$

*d.h.  $(X_n)$  ist nicht reversibel.*

## 2 Markov-Chain-Monte-Carlo-Simulation (MCMC)

## Motivation

Erzeugung synthetischer Daten als Ersatz für bzw. zur Ergänzung von experimentellen Daten.

Grundlage hierfür sind stochastische Simulationsalgorithmen, die sog. **Pseudozufallszahlen** generieren, welche einer gewünschten Verteilung folgen.

Bei der MCMC-Simulation nutzt man hierfür **Gleichgewichtszustände** der zugrundeliegenden Markov-Kette.

## Prinzip

1. Konstruktion einer Realisierung einer Markov-Kette  $X_0, X_1, \dots$ 
  - (a) mit Zustandsraum  $E$
  - (b) einer ergodischen Übergangsmatrix  $P$
  - (c) einer Grenzverteilung  $\pi$ .
2. Dann ist für großes  $n$ :  $X_n \stackrel{d}{\sim} \pi$  näherungsweise!

## Bemerkung 2.1

*Man hat die Frage zu untersuchen, wie lange obige Simulation laufen muss, bis die Näherung in einem (noch) zu definierenden mathematischen Sinne gut genug ist.*

Einen Ausweg bietet die sogenannte

### **perfekte Simulation**

bei der die Ausgabe der Simulation genau nach  $\pi$  verteilt ist.

Grundlage des bekanntesten Vertreters der auf MCMC-Methoden basierenden Algorithmen ist die **Kopplung** von Markov-Ketten ("Coupling"), weshalb wir diesen Begriff präzisieren.

## Theorem 2.2

- *Vor.:*

- $\forall i \in E$  sei eine ergodische Markov-Kette  $X^{(i)}$  gegeben durch:

$$X_n^{(i)} = \Phi(x_k, U_n^{(i)}), \text{ falls } X_{n-1}^{(i)} = x_k$$

wobei  $U^{(i)} = (U_1^{(i)}, U_2^{(i)}, \dots)$  eine Folge von unabhängigen und  $[0, 1]$ -gleichverteilten ZVen ist.

- Die Innovationenfolgen  $(U_k^{(i)})_{k \in \mathbb{N}}$  seien unabhängig  $\forall i \in E$ .

- *Beh.:*

- Für die sog. Kopplungszeit  $\tau := \min\{n \geq 1 : X_n^{(1)} = \dots = X_n^{(l)}\}$  gilt:

$$P(\tau < \infty) = 1$$

## 3 Propp-Wilson, Coupling-From-The-Past (CFTP)

## 3.1 Wiederholung und Spezialfälle

**Vor.:**

ergodische MK mit Übergangsfunktion  $\Phi$ , so dass  $X_k = \Phi(X_{k-1}, U_k)$ .

**Motivation:**

- Idee: Starte die MK im Zeitpunkt  $-\infty$ . Dann wäre sie zum Zeitpunkt 0 im Gleichgewichtszustand.
- Problem: "technisch" nicht machbar.
- Lösung: Coupling-From-The-Past

### Algorithmus 3.1 (CFTP)

1. Setze  $t := -T_1$  und generiere  $U = (U_{-T_1+1}, \dots, U_0)$ .
2. Starte eine Markov-Kette im Zeitpunkt  $t$  in allen Zuständen  $i \in E$  und entwickle bis zum Zeitpunkt 0 unter Verwendung derselben Innovationenfolge  $U \forall i \in E$ :

$$X_n^{(i)} = \Phi(x_{n-1}^{(i)}, U_n)$$

*Die Pfade verschmelzen also, sobald sie sich einmal getroffen haben.*

3. Wenn sich alle Pfade zum Zeitpunkt 0 in  $x_0 \in E$  getroffen haben:  
*STOP. Ausgabe:  $x_0$ .*
4. Setze  $t' := -T_2 < -T_1$ , generiere eine Innovationenfolge  $U' = (U_{-t'+1}, \dots, U_t)$ , setze  $U := (U', U)$ ,  $t := t'$  und gehe zu 2.

## heuristische Begründung

Bei Terminierung befinden sich alle generierten Ketten des obigen Algorithmus' zum Zeitpunkt 0 im gleichen Zustand  $x_0 \in E$ . Benutzt eine in  $-\infty$  gestartete Kette von  $-T_i$  bis 0 die gleichen Innovationen, würde sie zum Zeitpunkt 0 auch  $x_0$  realisieren. Also ist  $x_0$  virtuelles Ergebnis einer in  $-\infty$  beginnenden Simulation.

**Problem:**  $|E|$  groß:

- sehr viele Pfade müssen generiert werden
- immenser Rechen- und Speicheraufwand
- Implementierung des allgemeinen Falls nicht möglich

**Ausweg:** Implementierung nur unter Ausnutzung von Spezialfällen.

---

## wichtigster Spezialfall: Monotonie.

- auf  $E$  ist eine Halbordnung  $\preceq$  definiert mit Minimalelement  $\hat{0}$  und Maximalelement  $\hat{1}$ .
- Die Updatefunktion  $\Phi : E \times [0, 1] \rightarrow E$  ist monoton bzgl. " $\preceq$ ", d.h.  $\Phi(x, \cdot) \preceq \Phi(y, \cdot)$  für  $x \preceq y$
- $\forall i \in E$  wird die gleiche Innovationenfolge benutzt.

Dann reicht es aus, die Kette in den Zuständen  $\hat{0}$  und  $\hat{1}$  zu starten.

Verschmelzen diese beiden Pfade, so auch alle anderen, da diese (wegen Monotonie und Verwendung derselben Innovationenfolge für alle Zustände) dazwischen verlaufen.

## 3.2 Abhängigkeit des Outputs von der Laufzeit

Betrachte die Übergangsmatrix  $P = \begin{pmatrix} \frac{1}{2} & \frac{1}{2} & 0 \\ 0 & 0 & 1 \\ \frac{1}{2} & 0 & \frac{1}{2} \end{pmatrix}$  mit stationärer

Grenzverteilung  $\pi = (\frac{2}{5}, \frac{1}{5}, \frac{2}{5})$ .

Wir simulieren mit folgender Updatefunktion:

$x=0,2$ :

$$\Phi(x, U) = \begin{cases} 0 & \text{falls } U \leq \frac{1}{2} \\ \min\{x + 1, 2\} & \text{sonst} \end{cases}$$

$x=1$ :

$$\Phi(1, U) = 2$$

wobei  $U \sim \mathcal{U}[0, 1]$ . Für die Länge der  $i$ -ten Iteration gelte  $L(i) = 2^{i-1}$ .

## Beobachtungen

- Verschmelzung kann nicht im ersten Schritt auftreten.
- Danach sind die möglichen Zustände  $A = \{0, 2\}$  oder  $B = \{1, 2\}$
- In beiden Fällen ist die Verschmelzungswahrscheinlichkeit im nächsten Schritt  $\frac{1}{2}$ .

$$\begin{aligned} \mathbb{P}(Z = r|I) &= \frac{\mathbb{P}(\text{(Verschmelzung innerhalb } I \text{ Iterationen)} \wedge (Z = r))}{\mathbb{P}(\text{Verschmelzung innerhalb } I \text{ Iterationen})} \\ &= \frac{\sum_{k=2}^N (1 - \frac{1}{2})^{k-1} \cdot \frac{1}{2} [P^{N-k}(0, r) + P^{N-k}(2, r)]}{1 - (\frac{1}{2})^{N-1}} \end{aligned}$$

Für  $I = 2$  erhalten wir:  $\mathbb{P}(Z = 0|I = 2) = \frac{1}{2}$     $\mathbb{P}(Z = 2|I = 2) = \frac{1}{2}$ . Für  $I \geq 3$  ergibt sich:

$$\begin{aligned} \mathbb{P}(Z = 0|I) &= \frac{2}{5} \left[ \frac{1 - 2^{-N}}{1 - 2^{-N+1}} \right] \\ \mathbb{P}(Z = 1|I) &= \frac{1}{5} \left[ \frac{1 - 2^{-N}}{1 - 2^{-N+1}} \right] \\ \mathbb{P}(Z = 2|I) &= \frac{2}{5} \left[ \frac{1 - 7 \cdot 2^{-N-1}}{1 - 2^{-N+1}} \right] \end{aligned}$$

## 4 Der Fill-Algorithmus

## 4.1 Einführung

### Voraussetzungen

- Auf dem Grundraum  $E$  gebe es eine Halbordnung  $\preceq$  und eindeutig bestimmte Elemente  $\hat{0}$  und  $\hat{1}$ , so dass  $\hat{0} \preceq i \preceq \hat{1} \quad \forall i \in E$ .
- $\tilde{P}$  sei stochastisch monoton, d.h.

$$x \preceq y \Rightarrow \tilde{P}(x, \cdot) \preceq_{st} \tilde{P}(y, \cdot)$$

- Es gebe eine monotone Übergangsfunktion  $\tilde{\Phi}$  für  $\tilde{P}$ , d.h.

$$x \preceq y \Rightarrow \tilde{\Phi}(x, \cdot) \preceq \tilde{\Phi}(y, \cdot)$$

---

### Algorithmus 4.1 (Der Algorithmus von Fill für $\tilde{P}$ monoton)

1. Erzeuge eine Realisierung einer Markov-Kette  $X = (X_0, \dots, X_t)$  mit  $X_0 := \hat{0}$  gemäß der Vorschrift  $X_k = \Phi(X_{k-1}, U_k)$ ,  $U_k$  iid.
2. Bezeichne  $\tilde{X} := (\tilde{X}_0, \dots, \tilde{X}_t) = (X_t, \dots, X_0)$  die zeitinverse Markov-Kette von  $X$  mit monotoner Übergangsmatrix  $\tilde{P}$ ,  
 $\tilde{X}_k = \tilde{\Phi}(\tilde{X}_{k-1}, U'_k)$ ,  $U'_k$  iid.  
"Gekoppelt" an diesen Pfad  $\tilde{X}$  erzeuge eine neue Markov-Kette  $\tilde{Y} := (\tilde{Y}_0, \dots, \tilde{Y}_t)$  mit  $\tilde{Y}_0 := \hat{1}$  wie folgt:

(a) Generiere eine Folge von bedingt unabhängigen ZVen  $\hat{U}_k$  gemäß der Verteilung

$$Q(\tilde{X}_k, \tilde{X}_{k+1})(\cdot) = \mathbb{P}(U'_k \in \cdot | \tilde{\Phi}(\tilde{X}_k, U'_k) = \tilde{X}_{k+1}), \quad k = 0, \dots, t-1$$

(b) Setze

$$\tilde{Y}_k = \tilde{\Phi}(\tilde{Y}_{k-1}, \hat{U}_k), \quad k = 1, \dots, t$$

3. Ist  $\tilde{Y}_t = \hat{0}$ : STOP. Ausgabe:  $z = X_t$ .

4. Sonst: Lösche alle Informationen und starte eine neue Iteration mit  $t := 2t$  (z.B.)

## 4.2 Begründung

### Lemma 4.2 (Verwerfungsmethode)

- *Vor.:*
  - *Es seien  $\pi, \nu$  zwei Wkt.-Maße auf demselben Grundraum  $E$ .*
  - $\exists c > 0 : \pi(i) \leq c \cdot \nu(i) \quad \forall i \in E$
- *Beh.:*

*Folgender Algorithmus terminiert in endlicher Zeit und liefert eine nach  $\pi$  verteilte Stichprobe:*

  1. *Generiere eine Stichprobe  $x$  von  $X \sim \nu$ .*
  2. *Sei  $x = i$ .*

*Akzeptiere diesen Wert mit Wahrscheinlichkeit  $\frac{\pi(i)}{c \cdot \nu(i)}$ . STOP.*
  3. *Falls der Wert verworfen wird, gehe zurück zu 1.*

## Beweis

Es gilt:  $\mathbb{P}(X = i, X \text{ wird akzeptiert}) = \nu(i) \cdot \frac{\pi(i)}{c \cdot \nu(i)} = \frac{\pi(i)}{c}$

und

$$\begin{aligned} \mathbb{P}(X \text{ wird akzeptiert}) &\stackrel{U \sim \mathcal{U}(0,1]}{=} \mathbb{P}\left(U < \frac{\pi(X)}{c \cdot \nu(X)}\right) \\ &\stackrel{\text{bed. Wkt.}}{=} \sum_{i: \nu(i) > 0} \mathbb{P}\left(U < \frac{\pi(X)}{c \cdot \nu(X)} \mid X = i\right) \cdot \mathbb{P}(X = i) \\ &= \sum_{i: \nu(i) > 0} \mathbb{P}\left(U < \frac{\pi(i)}{c \cdot \nu(i)}\right) \cdot \nu(i) \end{aligned}$$

$$\begin{aligned} &= \sum_{i:\nu(i)>0} \frac{\pi(i)}{c \cdot \nu(i)} \cdot \nu(i) \\ &= \frac{1}{c} > 0 \end{aligned}$$

⇒ Algorithmus terminiert.

weiter gilt:

$$\mathbb{P}(X = i | X \text{ wird akzeptiert}) = \frac{\mathbb{P}(X = i, X \text{ wird akz.})}{\mathbb{P}(X \text{ wird akzeptiert})} = \frac{\frac{\pi(i)}{c}}{\frac{1}{c}} = \pi(i)$$

⇒ Behauptung.

- Eine Realisierung von  $X_t \stackrel{d}{\sim} P^t(\hat{0}, \cdot)$  wird benutzt, um eine Realisierung von  $\pi$  zu erhalten. (1. Phase)
- Zur Entscheidung, ob  $X_t$  gemäß  $\pi$  verteilt ist, wird die Verwerfungsmethode benutzt. (2. Phase). Wir suchen eine obere Schranke für  $\frac{\pi(z)}{P^t(\hat{0}, z)} \quad \forall z \in E$ .

Denn:  $\frac{\pi(z)}{P^t(\hat{0}, z)} \leq c \Leftrightarrow \pi(z) \leq c \cdot P^t(\hat{0}, z)$ .

Aus der Definition der zeitinversen Markov-Kette erhalten wir:

$$\tilde{P}^t(z, \hat{0}) = \frac{\pi(\hat{0})}{\pi(z)} \cdot P^t(\hat{0}, z) \Leftrightarrow \frac{\pi(\hat{0})}{\tilde{P}^t(z, \hat{0})} = \frac{\pi(z)}{P^t(\hat{0}, z)}$$

und wegen der Monotonie von  $\tilde{P}$  können wir  $c = \frac{\pi(\hat{0})}{\tilde{P}^t(\hat{1}, \hat{0})}$  setzen.

- Gemäß der Verwerfungsmethode akzeptieren wir eine Realisierung von  $P^t(\hat{0}, \cdot)$  mit der Wahrscheinlichkeit

$$\begin{aligned} \frac{\pi(z)}{c \cdot P^t(\hat{0}, z)} &= \frac{\pi(z)}{\frac{\pi(\hat{0})}{\tilde{P}^t(\hat{1}, \hat{0})} \cdot P^t(\hat{0}, z)} \\ &= \frac{\pi(z) \tilde{P}^t(\hat{1}, \hat{0}) \pi(\hat{0})}{\pi(\hat{0}) \tilde{P}^t(z, \hat{0}) \pi(z)} \\ &= \frac{\tilde{P}^t(\hat{1}, \hat{0})}{\tilde{P}^t(z, \hat{0})} \end{aligned}$$

### Theorem 4.3

$$\mathbb{P}(\tilde{Y}_t = \hat{0} | \tilde{X}_0 = z, \tilde{X}_t = \hat{0}, \tilde{Y}_0 = \hat{1}) = \frac{\tilde{P}^t(\hat{1}, \hat{0})}{\tilde{P}^t(z, \hat{0})}$$

### Beweis

Durch das Design der MK  $\tilde{Y}$  gilt:  $\tilde{X}_s \preceq \tilde{Y}_s \quad \forall s \in \{0, \dots, t\}$ ,  
insbesondere also  $\tilde{Y}_t = \hat{0} \Rightarrow \tilde{X}_t = \hat{0}$ .

Denn induktiv ergibt sich:

$$(IA) \quad \tilde{X}_0 = X_t = z \preceq \hat{1} = \tilde{Y}_0$$

$$(IS) \quad \tilde{X}_s = \tilde{\Phi}(\tilde{X}_{s-1}, U'_s) \preceq \tilde{\Phi}(\tilde{Y}_{s-1}, U'_s) \preceq \tilde{\Phi}(\tilde{Y}_{s-1}, \hat{U}_s) = \tilde{Y}_s$$

Desweiteren betrachten wir die gemeinsame Verteilung der Ketten  $\tilde{Y}$  und  $\tilde{X}$ :

$$\begin{aligned}
 & \mathbb{P}(\tilde{Y} = y, \tilde{X} = x) \\
 &= \prod_{s=1}^k \tilde{P}(x_{s-1}, x_s) \mathbb{P}(\tilde{Y}_s = y_s | \tilde{Y}_{s-1} = y_{s-1}, \tilde{X}_s = x_s, \tilde{X}_{s-1} = x_{s-1}) \\
 &= \prod_{s=1}^k \mathbb{P}(\tilde{\Phi}(x_{s-1}, U'_s) = x_s) \mathbb{P}(\tilde{\Phi}(y_{s-1}, \hat{U}_s) = y_s | \tilde{\Phi}(x_{s-1}, \hat{U}_s) = x_s) \\
 &= \prod_{s=1}^k \mathbb{P}(\tilde{\Phi}(y_{s-1}, \hat{U}_s) = y_s) \\
 &= \mathbb{P}(\tilde{Y} = y)
 \end{aligned}$$

Mit diesen zwei Teilergebnissen können wir berechnen:

$$\begin{aligned}
 \mathbb{P}(\tilde{Y}_t = \hat{0} | \tilde{X}_0 = z, \tilde{X}_t = \hat{0}, \tilde{Y}_0 = \hat{1}) &= \frac{\mathbb{P}(\tilde{Y}_t = \hat{0}, \tilde{X}_t = \hat{0} | \tilde{X}_0 = z, \tilde{Y}_0 = \hat{1})}{\mathbb{P}(\tilde{X}_t = \hat{0} | \tilde{X}_0 = z, \tilde{Y}_0 = \hat{1})} \\
 &= \frac{\mathbb{P}(\tilde{Y}_t = \hat{0} | \tilde{X}_0 = z, \tilde{Y}_0 = \hat{1})}{\tilde{P}^t(z, \hat{0})} = \frac{\mathbb{P}(\tilde{Y}_t = \hat{0}, \tilde{X}_0 = z | \tilde{Y}_0 = \hat{1})}{\tilde{P}^t(z, \hat{0}) \cdot \mathbb{P}(\tilde{X}_0 = z, \tilde{Y}_0 = \hat{1})} \\
 &= \frac{\tilde{P}^t(\hat{1}, \hat{0})}{\tilde{P}^t(z, \hat{0})}
 \end{aligned}$$

woraus die Behauptung folgt.

## Bemerkung 4.4

1. *Aus Theorem 4.2 folgt*

$$\mathbb{P}(X_t \text{ wird akzeptiert}) = \frac{1}{c} = \frac{\tilde{P}^t(\hat{1}, \hat{0})}{\pi(\hat{0})} = \frac{P^t(\hat{0}, \hat{1})}{\pi(\hat{1})} \longrightarrow 1 \quad (t \rightarrow \infty)$$

2. *Die Aussage, dass der Fill-Algorithmus durch einen ungeduldigen Benutzer unbeeindruckt bleibt, folgt aus der Natur der Verwerfungsmethode.*

## 5 Beispiel: Das Ising-Modell

## 5.1 Modellbeschreibung

- Betrachten ein Gitter  $G = (V, K)$  mit
  - $V = \{v_1, \dots, v_{|V|}\}$  Menge der Eckpunkte (endlich)
  - $K \subset V^2$  Menge der Kanten, die jeweils zwei Eckpunkte miteinander verbinden.
  - $K \ni e = (v_i, v_j)$  verbindet die Eckpunkte  $v_i, v_j \in V$ .
- Jedem Eckpunkt wird der Wert  $-1$  oder  $1$  zugeordnet.  
 $\Rightarrow$  Zustandsraum  $E = \{-1, 1\}^{|V|}$  "Menge aller Konfigurationen".  
 $x = (x(v), v \in V)$  mit  $x(v) \in \{-1, 1\} \quad \forall v \in V$ .
- Zur grafischen Veranschaulichung interpretiert man
  - weißes Pixel:  $x(v) = -1$
  - schwarzes Pixel:  $x(v) = 1$

- Man betrachtet die Wahrscheinlichkeit  $\pi_x$ , dass die Konfiguration  $x \in E$  angenommen wird.  
 $\pi$  ist gegeben durch

$$\pi_x := \frac{1}{Z_{G,J}} \exp \left( J \sum_{e=(v_i, v_j) \in K} x(v_i) x(v_j) \right)$$

wobei

–  $J \geq 0$  Parameter

–  $Z_{G,J} := \sum_{x \in E} \exp \left( -J \sum_{e=(v_i, v_j) \in K} x(v_i) x(v_j) \right)$

Normierungskonstante

---

## Algorithmus 5.1 *Gibbs-Sampler*

1. *Wähle eine Komponente  $v \in V$  aus (nach Gleichverteilung).*
2. *Ändere  $x(v)$  gemäß der bedingten Verteilung  $\pi_{x(v)|x(-v)}$   
 $x(-v) := (x(w), w \in V \setminus \{v\})$ .*
3. *Übernehme alle anderen Komponenten.*

Man erhält dann die Übergangsmatrix  $P = (p_{xx'})$  von  $X$  gegeben durch

$$p_{xx'} = \sum_{v \in V} \frac{1}{|V|} \pi_{x'(v)|x(-v)} \mathbf{1}_{(x(-v)=x'(-v))} \quad \forall x, x' \in E$$

mit der bedingten Verteilung

$$\pi_{x'(v)|x(-v)} = \begin{cases} \frac{1}{1 + \exp(-2J(K_+(x(-v)) - K_-(x(-v))))} & \text{falls } x'(v) = 1 \\ \frac{1}{1 + \exp(-2J(K_-(x(-v)) - K_+(x(-v))))} & \text{falls } x'(v) = -1 \end{cases}$$

wobei  $K_+(x(-v))$  bzw.  $K_-(x(-v))$  die Anzahl derjenigen mit  $v$  verbundenen Eckpunkte ist, die auf 1 bzw. -1 gesetzt sind.

Eine Updatefunktion  $\Phi : E \times (0, 1]^2 \rightarrow E$  ist gegeben durch

$$\Phi(x; U_1, U_2) = x', \quad x' = (x'(v), v \in V)$$

wobei

$$x'(v_i) = \begin{cases} 1, & \text{falls } \frac{i-1}{|V|} < U_1 \leq \frac{i}{|V|} \text{ und } U_2 < \pi_{1|x}(-v_i) \\ -1, & \text{falls } \frac{i-1}{|V|} < U_1 \leq \frac{i}{|V|} \text{ und } U_2 \geq \pi_{1|x}(-v_i) \\ x(v_i) & \text{sonst} \end{cases}$$

Für diese Updatefunktion gilt

$$\Phi(x; U_1, U_2) \preceq \Phi(y; U_1, U_2) \quad \forall x \preceq y, \quad \forall U_1, U_2 \in (0, 1]$$

d.h. sie ist monoton.

## 5.2 Implementierung mit CFTP

### Algorithmus 5.2 CFTP für das Ising-Modell

1. Wähle  $T$  und setze  $X_{-T} = \hat{0}, Y_{-T} = \hat{1}$ .
2. Generiere auf  $(0, 1]$  gleichverteilte Pseudozufallszahlen  $U_1^{(1)}, \dots, U_1^{(T)}$  und  $U_2^{(1)}, \dots, U_2^{(T)}$ .  
Berechne  $X_{-T}, \dots, X_0$  und  $Y_{-T}, \dots, Y_0$  mit Hilfe von  $\Phi$ .
3. Falls  $X_0 = Y_0$ : STOP.  
Falls  $X_0 \neq Y_0$ : Erhöhe  $T$  und gehe zu Schritt 1.

## 5.3 Implementierung mit Fill

- Bezeichne  $\tilde{X}$  die zeitinverse MK von  $X$ .
- Betrachte den Übergang vom Zustand  $x$  in den Zustand  $x'$ , d.h.  
$$x' = \tilde{\Phi}(x, U'_1, U'_2)$$

Herleitung von Regeln für den Übergang von  $y$  nach  $y'$ :

- Die jeweils für die Wahl des zu ändernden Pixels verantwortliche Innovation  $U_1$  kann für  $\tilde{Y}$  übernommen werden:  $\hat{U}_1 = U_1$ .
- Bei der Art der Änderung sind drei Fälle zu unterscheiden:

1.  $x' \neq x$  und  $x'(v_i) = 1$  wurde geändert:

wegen  $\tilde{X}_t \preceq \tilde{Y}_t \quad \forall t$ , setzt man  $y'(v_i) = 1$ .

2.  $x' \neq x$  und  $x'(v_i) = -1$  wurde geändert:

wegen  $U_2 \leq \pi_{-1|x(-v)} \Rightarrow \hat{U}_2 \sim \mathcal{U}(0, \pi_{-1|x(-v_i)})$ .

Erzeuge hierzu  $U_2^* \sim \mathcal{U}[0, 1]$  und setze  $\hat{U}_2 = U_2^* \cdot \pi_{-1|x(-v_i)}$ .

Übergangsregel:

$$y'(v_i) = \begin{cases} -1, & \text{falls } U_2^* \leq \frac{\pi_{-1|y(-v_i)}}{\pi_{-1|x(-v_i)}} \\ 1, & \text{sonst} \end{cases}$$

3.  $x' = x$

Setze  $\hat{U}_1 = U_1$  und  $\hat{U}_2 = U_2$ . Denn:

Betrachte den Fall  $U_1 = i, U_2 \leq \pi_{-1|x}(-v_i)$ , wir erhalten dann folgende bedingte Verteilung für  $(U_1, U_2)$ :

$$\begin{aligned} \Rightarrow (U_1, U_2) &\sim F(U_1, U_2 | \tilde{\Phi}(U_1, U_2, x) = x) = F(i, U_2 | \tilde{\Phi}(i, U_2, x) = x) \\ &= F(i, U_2 | U_2 \leq \pi_{-1|x}(-v_i)) = F(i, U_2 \cdot \pi_{-1|x}(-v_i)) \end{aligned}$$

Andererseits

$$\begin{aligned} (\hat{U}_1, \hat{U}_2) &\sim F(U'_1, U'_2 | \tilde{\Phi}(U'_1, U'_2, x) = x) \\ &= F(i, U'_2 \cdot \pi_{-1|x}(-v_i)) \end{aligned}$$

Für  $U_2 \stackrel{d}{=} U'_2$  folgt die Behauptung.

Insgesamt erhält man also folgende Update-Regel für  $\tilde{Y}$ :

$$y'(v_i) = \begin{cases} 1, & \text{falls } x' \neq x \text{ und } x'(v_i) = 1 \text{ geändert} \\ -1, & \text{falls } x' \neq x \text{ und } x'(v_i) = -1 \text{ geändert und } U_2^* \leq \frac{\pi_{-1|y(-v_i)}}{\pi_{-1|x(-v_i)}} \\ 1, & \text{falls } x' \neq x \text{ und } x'(v_i) = -1 \text{ geändert und } U_2^* > \frac{\pi_{-1|y(-v_i)}}{\pi_{-1|x(-v_i)}} \\ y(v_i), & \text{falls } x' \neq x \text{ und } x'(v_i) \text{ nicht geändert} \\ 1, & \text{falls } x' = x \text{ und } \frac{i-1}{|V|} < U_1 \leq \frac{i}{|V|} \text{ und } U_2 \leq \pi_{1|x(-v_i)} \\ -1, & \text{falls } x' = x \text{ und } \frac{i-1}{|V|} < U_1 \leq \frac{i}{|V|} \text{ und } U_2 > \pi_{1|x(-v_i)} \\ y(v_i), & \text{falls } x' = x \text{ und } (U_1 \leq \frac{i-1}{|V|} \text{ oder } U_1 > \frac{i}{|V|}) \end{cases}$$

### Algorithmus 5.3 (Fill-Algorithmus für das Ising-Modell)

1. Wähle  $T$  und setze  $X_0 = \hat{0}$ ,  $\tilde{Y}_0 = \hat{1}$ .
2. Generiere auf  $(0, 1]$  gleichverteilte Pseudozufallszahlen  $U_1^{(1)}, \dots, U_1^{(T)}$  und  $U_2^{(1)}, \dots, U_2^{(T)}$ . Berechne  $X_0, \dots, X_T$  mit Hilfe von  $\Phi$  und anschließend die zeitinverse MK  $\tilde{X}$ .
3. Berechne  $\tilde{Y}_0, \dots, \tilde{Y}_T$  mit Hilfe eben genannter Regel.
4. Falls  $\tilde{Y}_T = \hat{0}$ , akzeptiere  $X_T = z$ . STOP.  
Falls  $\tilde{Y}_T \neq \hat{0}$ , erhöhe  $T$  und gehe zu Schritt 2.

## 6 Vergleich

	<b>CFTP</b>	<b>Fill</b>
Idee	Rückwärtskopplung	Verwerfungsmethode
Anwendbarkeit	erfordert monotone Übergangsfunktion	nicht notwendigerweise monotone Übergangsfunktion, aber aufwendigere Generierung der Ketten
Erweiterbarkeit	stetiger Zustandsraum und inhomogene MK	dto.
Performance	benötigt weniger Speicher	benötigt weniger Iterationen

## Literatur

- [1] Fill, James A., *An Interruptible Algorithm For Perfect Sampling Via Markov-Chains*, The Johns Hopkins University, Baltimore, 1998
- [2] Fismen, Morten, *Exact Simulation using Markov-Chains*, The Norwegian University Of Technology And Science, Trondheim, 1997
- [3] Huber, Marc, *Perfect Sampling Without A Lifetime Commitment*, Cornell University, Ithaca
- [4] König, Wolfgang, *Vorlesungsskript zu Stochastische Algorithmen*, Universität Köln, 2003
- [5] Møller, Jesper und Schladitz, Katja, *Extensions Of Fill's Algorithm For Perfect Simulation*, Aalborg University, 1998

- [6] Schmidt, Volker, *Vorlesungsskript zu Markov-Ketten und Monte-Carlo-Simulation*, Universität Ulm, 2003
- [7] Thönnies, Elke, *Perfect Simulation Of Some Point Processes For The Impatient User*, University Of Warwick, Coventry, 1998

**Vielen Dank für die Aufmerksamkeit!**