

# Randomisierte Algorithmen

## 9. Metropolis-Hastings-Algorithmus

Thomas Worsch

Fakultät für Informatik  
Karlsruher Institut für Technologie

Wintersemester 2019/2020

# Überblick

Zeitreversible Markovketten

Metropolis-Algorithmus

Simulated Annealing

# Überblick

Zeitreversible Markovketten

Metropolis-Algorithmus

Simulated Annealing

## Definition Zeitreversibilität

ergodische Markov-Kette ist *(zeit-)reversibel (in detailed balance)*, wenn es Wahrscheinlichkeitsverteilung  $\mathbf{w}$  auf der Zustandsmenge  $S$  gibt so, dass für alle  $i, j \in S$  gilt:

$$\mathbf{w}_i P_{ij} = \mathbf{w}_j P_{ji} .$$

## Lemma

▶ wenn

▶  $M$  Markov-Kette und

▶  $\mathbf{q}$  Verteilung mit

$$\mathbf{q}_i P_{ij} = \mathbf{q}_j P_{ji}$$

für alle Zustände  $i$  und  $j$ ,

▶ dann ist  $\mathbf{q}$  eine stationäre Verteilung von  $M$ .

## Beweis

Für alle  $i$  ist

$$(\mathbf{q}P)_i = \sum_j \mathbf{q}_j P_{ji} = \sum_j \mathbf{q}_i P_{ij} = \mathbf{q}_i \sum_j P_{ij} = \mathbf{q}_i .$$

## Mitteilung: Kriterium von Kolmogorov

### Satz

Eine ergodische Markov-Kette ist genau dann(zeit-)reversibel, wenn für alle Folgen  $(i_0, i_1, \dots, i_n, i_0)$  von Zuständen gilt:

$$\begin{aligned} & P_{i_0 i_1} \cdot P_{i_1 i_2} \cdots P_{i_{n-1} i_n} \cdot P_{i_n i_0} \\ &= P_{i_0 i_n} \cdot P_{i_n i_{n-1}} \cdots P_{i_2 i_1} \cdot P_{i_1 i_0} \end{aligned}$$

ohne Beweis

## Von ungerichteten Graphen zu reversible Markovketten

- ▶  $G = (V, E)$  ein zusammenhängender ungerichteter Graph ohne Schlingen
- ▶  $0 < \beta \leq 1$  eine reelle Zahl
- ▶  $d(i)$  Grad von Knoten  $i$  und  $d = \max_{i \in V} d(i)$
- ▶ definiere Markov-Kette  $M_{G, \beta}$ :

$$P_{ij} = \begin{cases} \beta/d & \text{falls } i \neq j \text{ und } (i, j) \in E \\ 0 & \text{falls } i \neq j \text{ und } (i, j) \notin E \\ 1 - d(i)\beta/d & \text{falls } i = j \end{cases}$$



## Von ungerichteten Graphen zu reversible Markovketten


- ▶  $G = (V, E)$  ein zusammenhängender ungerichteter Graph ohne Schlingen
- ▶  $0 < \beta \leq 1$  eine reelle Zahl
- ▶  $d(i)$  Grad von Knoten  $i$  und  $d = \max_{i \in V} d(i)$
- ▶ definiere Markov-Kette  $M_{G, \beta}$ :

$$P_{ij} = \begin{cases} \beta/d & \text{falls } i \neq j \text{ und } (i, j) \in E \\ 0 & \text{falls } i \neq j \text{ und } (i, j) \notin E \\ 1 - d(i)\beta/d & \text{falls } i = j \end{cases}$$


$$P_{ij} = \begin{cases} \beta/d & \text{falls } i \neq j \text{ und } (i, j) \in E \\ 0 & \text{falls } i \neq j \text{ und } (i, j) \notin E \\ 1 - \sum_{i \neq k} P_{ik} & \text{falls } i = j \end{cases}$$

# Von ungerichteten Graphen zu reversible Markovketten

## Beispiel




$\beta = 1$




# Von ungerichteten Graphen zu reversible Markovketten

## Beispiel





$\beta = 1$




# Von ungerichteten Graphen zu reversible Markovketten

## Beispiel



# Von ungerichteten Graphen zu reversible Markovketten

## Beispiel



## Beobachtung/Übung

- ▶ Kette irreduzibel, da Graph zusammenhängend
- ▶ für  $\beta < 1$  Kette aperiodisch
- ▶ stationäre Verteilung  $M_{G,\beta}$ : Gleichverteilung
- ▶ für  $\beta < 1$  Kette reversibel

## Verallgemeinerung: reversible Markovketten

mit frei wählbarer Wahrscheinlichkeitsverteilung

- ▶  $G = (V, E)$  ein zusammenhängender ungerichteter Graph
  - ▶  $0 < \beta < 1$  eine reelle Zahl
  - ▶  $d(i)$  Grad von Knoten  $i$  und  $d = \max_{i \in V} d(i)$
- ▶  $\mathbf{p}$  eine W.verteilung auf  $V$ , **nirgends 0**, sonst beliebig

## Verallgemeinerung: reversible Markovketten

mit frei wählbarer Wahrscheinlichkeitsverteilung

- ▶  $G = (V, E)$  ein zusammenhängender ungerichteter Graph
  - ▶  $0 < \beta < 1$  eine reelle Zahl
  - ▶  $d(i)$  Grad von Knoten  $i$  und  $d = \max_{i \in V} d(i)$
- ▶  $\mathbf{p}$  eine W.verteilung auf  $V$ , **nirgends 0**, sonst beliebig
- ▶ definiere Markov-Kette  $M_{G, \beta, \mathbf{p}}$ :

$$P_{ij} = \begin{cases} \min(1, \frac{p_j}{p_i}) \cdot \beta/d & \text{falls } i \neq j \text{ und } (i, j) \in E \\ 0 & \text{falls } i \neq j \text{ und } (i, j) \notin E \\ 1 - \sum_{i \neq k} P_{ik} & \text{falls } i = j \end{cases}$$



## Verallgemeinerung: reversible Markovketten

mit frei wählbarer Wahrscheinlichkeitsverteilung

- ▶  $G = (V, E)$  ein zusammenhängender ungerichteter Graph
  - ▶  $0 < \beta < 1$  eine reelle Zahl
  - ▶  $d(i)$  Grad von Knoten  $i$  und  $d = \max_{i \in V} d(i)$
- ▶  $\mathbf{p}$  eine W.verteilung auf  $V$ , **nirgends 0**, sonst beliebig
- ▶ definiere Markov-Kette  $M_{G,\beta,\mathbf{p}}$ :

$$P_{ij} = \begin{cases} \min(1, \frac{p_j}{p_i}) \cdot \beta/d & \text{falls } i \neq j \text{ und } (i, j) \in E \\ 0 & \text{falls } i \neq j \text{ und } (i, j) \notin E \\ 1 - \sum_{i \neq k} P_{ik} & \text{falls } i = j \end{cases}$$

### Lemma

$M_{G,\beta,\mathbf{p}}$  ist zeitreversibel mit stationärer Verteilung  $\mathbf{p}$ .

## Verallgemeinerung

### Beweis

- Reversibilität:

Sei  $i \neq j$  und  $(i, j) \in E$  (alles andere trivial):

$$\begin{aligned} \frac{p_i P_{ij}}{p_j P_{ji}} &= \frac{p_i \min(1, \frac{p_j}{p_i}) \cdot \beta/d}{p_j \min(1, \frac{p_i}{p_j}) \cdot \beta/d} \\ &= \begin{cases} \frac{p_i}{p_j} / \frac{p_i}{p_j} & \text{falls } p_i \leq p_j \\ \frac{p_i}{p_j} \cdot \frac{p_j}{p_i} & \text{falls } p_i > p_j \end{cases} \\ &= 1 \end{aligned}$$

- stationäre Verteilung: klar

# Überblick

Zeitreversible Markovketten

**Metropolis-Algorithmus**

Simulated Annealing

## MCMC: Markov Chain Monte Carlo

- ▶ eine Methode für *Sampling*
  - ▶ zufällige Auswahl von Elementen aus einer Grundmenge  $S$
  - ▶ gemäß einer Wahrscheinlichkeitsverteilung  $\mathbf{p}$
- ▶ *Idee von MCMC*
  - ▶ konstruiere Markovkette  $\mathbf{P}$  mit Zustandsmenge  $S$  so, dass
  - ▶  $\mathbf{p}$  die stationäre Verteilung ist, und
  - ▶ mache Random Walk mit Übergangswahrscheinlichkeiten  $\mathbf{P}_{ij}$
- ▶ *Probleme*
  - ▶ woher  $\mathbf{P}$ ?
  - ▶ was, wenn  $\mathbf{p}$  nicht explizit gegeben
    - ▶ sondern nur Zahlen  $z_i$  proportional zu den  $\mathbf{p}_i$  und
    - ▶  $S$  *extrem* groß und
    - ▶ Normalisierungsfaktor  $Z = \sum_{i \in S} z_i$  nicht handhabbar

## Originalliteratur: Metropolis et al. und Hastings



Metropolis, N., Rosenbluth, A.W., Rosenbluth, M.N., Teller, A.H.;  
Teller, E.:

*Equations of State Calculations by Fast Computing Machines*

Journal of Chemical Physics. 21 (6): 1087–1092. 1953



Hastings, W.K.

*Monte Carlo Sampling Methods Using Markov Chains and Their  
Applications*

Biometrika. 57 (1): 97–109, 1970.

laut [https](https://en.wikipedia.org/wiki/Metropolis-Hastings_algorithm#History):

[//en.wikipedia.org/wiki/Metropolis-Hastings\\_algorithm#History](https://en.wikipedia.org/wiki/Metropolis-Hastings_algorithm#History)  
und dort angegebenen Quellen sind die Ursprünge nicht ganz so klar

## Metropolis-Hastings: die Markovkette

- ▶ gegeben
  - ▶ Zustandsmenge  $S$
  - ▶ Zahlen  $z_i$  für  $i \in S$  und damit (implizit) Wahrscheinlichkeiten  $p_i = z_i/Z$  mit  $Z = \sum_{i \in S} z_i$
  - ▶ *proposal matrix*  $Q$ 
    - ▶ Übergangsmatrix einer irreduziblen Markovkette
- ▶ definiere für alle  $i, j \in S$ :
  - ▶ Akzeptanzwahrscheinlichkeiten  $\alpha_{ij}$ 
    - ▶ für  $i \neq j$  und  $Q_{ij} \neq 0$ :
 
$$\alpha_{ij} = \min \left\{ 1, \frac{p_j Q_{ji}}{p_i Q_{ij}} \right\}$$
    - ▶ anderfalls  $\alpha_{ij} = 0$
  - ▶ Übergangswahrscheinlichkeiten:

$$P_{ij} = \begin{cases} \alpha_{ij} Q_{ij}, & \text{falls } i \neq j \\ 1 - \sum_{k \neq i} P_{ik}, & \text{sonst} \end{cases}$$

## Metropolis-Hastings: die Markovkette

- ▶ gegeben
  - ▶ Zustandsmenge  $S$
  - ▶ Zahlen  $z_i$  für  $i \in S$  und damit (implizit) Wahrscheinlichkeiten  $p_i = z_i/Z$  mit  $Z = \sum_{i \in S} z_i$
  - ▶ *proposal matrix*  $Q$ 
    - ▶ Übergangsmatrix einer irreduziblen Markovkette
- ▶ definiere für alle  $i, j \in S$ :
  - ▶ Akzeptanzwahrscheinlichkeiten  $\alpha_{ij}$ 
    - ▶ für  $i \neq j$  und  $Q_{ij} \neq 0$ :
 
$$\alpha_{ij} = \min \left\{ 1, \frac{p_j Q_{ji}}{p_i Q_{ij}} \right\} = \min \left\{ 1, \frac{z_j Q_{ji}}{z_i Q_{ij}} \right\}$$
    - ▶ anderfalls  $\alpha_{ij} = 0$
  - ▶ Übergangswahrscheinlichkeiten:

$$P_{ij} = \begin{cases} \alpha_{ij} Q_{ij}, & \text{falls } i \neq j \\ 1 - \sum_{k \neq i} P_{ik}, & \text{sonst} \end{cases}$$

## Metropolis-Hastings: als Algorithmus

- ▶ starte in beliebigem  $i_0 \in S$
- ▶ Schritt von Zustand  $i_t \in S$  zu  $i_{t+1}$  in zwei Phasen:
  - ▶ wähle gemäß Verteilung  $\mathbf{q}_j = Q(i_t, j)$  zufällig  $j \in S$
  - ▶ berechne

$$\alpha_{ij} = \begin{cases} \min \left\{ 1, \frac{p_j Q_{ji}}{p_i Q_{ij}} \right\}, & \text{falls } i \neq j \text{ und } Q_{ij} \neq 0 \\ 0, & \text{sonst} \end{cases}$$

- ▶ wähle

$$i_{t+1} = \begin{cases} j & \text{mit Wahrscheinlichkeit } \alpha_{ij} Q_{ij} \\ i_t & \text{sonst} \end{cases}$$



## Ising Modell

- ▶ Modell für Ferromagnetismus
- ▶ gegeben (vereinfacht)
  - ▶ Gitter  $L$
  - ▶ an jedem Knoten  $i$  ein *Spin*  $\sigma_i \in \{-1, 1\}$
  - ▶ *Konfiguration*  $\sigma : L \rightarrow \{-1, 1\}$
  - ▶ *Energie*  $H(\sigma) = - \sum_{ij} J_{ij} \sigma_i \sigma_j$ 
    - ▶ typisch  $J_{ij} = \begin{cases} 1, & \text{falls } i \text{ und } j \text{ direkte Nachbarn} \\ 0, & \text{sonst} \end{cases}$
  - ▶ (Konfigurations-)Wahrscheinlichkeit von  $\sigma$  ist
    - ▶ proportional zu  $e^{-\beta H(\sigma)}$
    - ▶ für ein  $\beta \geq 0$  «inverse Temperatur»
- ▶ gewünscht: Sampling von  $\sigma$  mit Wahrscheinlichkeiten  $P_\beta(\sigma) = e^{-\beta H(\sigma)} / Z(\beta)$  wobei  $Z(\beta) = \sum_\sigma e^{-\beta H(\sigma)}$

## Ising Modell: Metropolis-Hastings

- ▶ starte mit zufälligem  $\sigma^0$
- ▶ zu gegebenem  $\sigma^t$   
nutze  $\mathbf{Q}$ : flippe *einen* zufällig gewählten Spin  $\rightsquigarrow \sigma'$
- ▶ Metropolis-Hastings
  - ▶ falls  $H(\sigma') \leq H(\sigma)$ , wähle  $\sigma^{t+1} = \sigma'$ .
  - ▶ falls  $H(\sigma') > H(\sigma)$ , wähle

$$\sigma^{t+1} = \begin{cases} \sigma' & \text{mit Wahrscheinlichkeit } e^{\beta(H(\sigma^t) - H(\sigma'))} \\ \sigma & \text{sonst} \end{cases}$$

# Überblick

Zeitreversible Markovketten

Metropolis-Algorithmus

**Simulated Annealing**

## Optimierungsproblem

- ▶ gegeben:  $f: S \rightarrow \mathbb{R}$ 
  - ▶  $f^* = \max\{f(x) \mid x \in S\}$  möge existieren (z. B.  $S$  endlich)
- ▶ gesucht: ein  $x$  mit  $f(x) = f^*$

## Markovketten $M_\lambda$

- ▶ sei  $1 \leq \lambda \in \mathbb{R}_+$  («inverse Temperatur»)
- ▶ definiere stationäre Verteilungen  $\mathbf{w}_\lambda$  durch

$$\mathbf{w}_{\lambda x} = \frac{\lambda^{f(x)}}{Z(\lambda)}$$

mit  $Z(\lambda) = \sum_{x \in S} \lambda^{f(x)}$

- ▶ Markovkette  $M_\lambda$ 
  - ▶ Metropolis-Algorithmus mit
  - ▶ stationärer Verteilung  $\mathbf{w}_\lambda$
- ▶ falls  $f(x) > f(y)$ , Übergang von Zustand  $x$  nach  $y$  mit Wahrscheinlichkeit

$$\lambda^{-(f(x)-f(y))}$$

## Simulated Annealing

- ▶ Random Walk auf *sich ändernder* Markovkette
- ▶ beginne mit  $\lambda = 1$ , d. h.
  - ▶ «zielloses Umherirren»

## Simulated Annealing

- ▶ Random Walk auf *sich ändernder* Markovkette
- ▶ beginne mit  $\lambda = 1$ , d. h.
  - ▶ «zielloses Umherirren»
- ▶ erhöhe  $\lambda$  langsam d. h.

## Simulated Annealing

- ▶ Random Walk auf *sich ändernder* Markovkette
- ▶ beginne mit  $\lambda = 1$ , d. h.
  - ▶ «zielloses Umherirren»
- ▶ erhöhe  $\lambda$  langsam d. h.
  - ▶ vermeide zunehmend neue Zustände  $y$ , für die  $f(y)$  kleiner als der aktuelle Wert
- ▶ für  $\lambda \rightarrow \infty$  ergibt sich stationäre Verteilung, in nur noch Zustände  $x$  mit maximalem  $f(x) = f^*$  vorkommen.



## Simulated Annealing (2)

Es sei  $S^* = \{x \mid f(x) = f^*\}$

$$\begin{aligned} \mathbf{w}_{\lambda x} &= \frac{\lambda^{f(x)}}{Z(\lambda)} = \frac{\lambda^{f(x)}}{\sum_{x \in S} \lambda^{f(x)}} \\ &= \frac{\lambda^{f(x)} / \lambda^{f^*}}{\sum_{x \in S} \lambda^{f(x)} / \lambda^{f^*}} \\ &= \frac{\lambda^{f(x)} / \lambda^{f^*}}{|S^*| + \sum_{x \in S \setminus S^*} \lambda^{f(x)} / \lambda^{f^*}} \end{aligned}$$

Also

$$\lim_{\lambda \rightarrow \infty} \mathbf{w}_{\lambda x} = \begin{cases} 1/|S^*| & \text{falls } x \in S^* \\ 0 & \text{sonst} \end{cases}$$