

Randomisierte Algorithmen

10. Schnell mischende Markov-Ketten

Thomas Worsch

Fakultät für Informatik
Karlsruher Institut für Technologie

Wintersemester 2019/2020

Überblick

Anmerkungen zu Eigenwerten

Konvergenzverhalten ergodischer Markov-Ketten

Schnell mischende Markov-Ketten

Ein schönes Buch

David A. Levin, Yuval Peres, Elizabeth L. Wilmer:
Markov Chains and Mixing Times
AMS (2008)

<http://darkwing.uoregon.edu/~dlevin/MARKOV/markovmixing.pdf>

Überblick

Anmerkungen zu Eigenwerten

Konvergenzverhalten ergodischer Markov-Ketten

Schnell mischende Markov-Ketten

Lemma

Es sei P eine zeilenstochastische Matrix.

- ▶ Dann ist 1 ein Eigenwert von P .
- ▶ Für jeden Eigenwert λ von P gilt: $|\lambda| \leq 1$.

Beweis

- ▶ Erster Teil klar wegen $P(1, \dots, 1)^T = (1, \dots, 1)^T$.
- ▶ sei $\lambda \in \mathbb{C}$ Eigenwert mit $P(x_1, \dots, x_n)^T = \lambda(x_1, \dots, x_n)^T$
und i_0 ein Index mit $|x_{i_0}| = \max_j |x_j|$.

Beweis

- ▶ Erster Teil klar wegen $P(1, \dots, 1)^T = (1, \dots, 1)^T$.
- ▶ sei $\lambda \in \mathbb{C}$ Eigenwert mit $P(x_1, \dots, x_n)^T = \lambda(x_1, \dots, x_n)^T$ und i_0 ein Index mit $|x_{i_0}| = \max_j |x_j|$.
- ▶ dann

$$\begin{aligned} |\lambda| \cdot |x_{i_0}| &= |\lambda \cdot x_{i_0}| = \left| \sum_j P_{i_0 j} x_j \right| \\ &\leq \sum_j P_{i_0 j} |x_j| \leq \sum_j P_{i_0 j} |x_{i_0}| \\ &= |x_{i_0}| \sum_j P_{i_0 j} = |x_{i_0}|. \end{aligned}$$

also $|\lambda| \leq 1$.

Lemma

sei P stochastische Matrix

- ▶ einer reversiblen Markov-Kette
- ▶ mit $|S| = N$ Zuständen

dann besitzt P

- ▶ nur reelle Eigenwerte
- ▶ mit $1 = \lambda_1 > \lambda_2 \geq \dots \geq \lambda_N > -1$.

Beweis: lineare Algebra ...

Abkürzung

- ▶ $\lambda_{max} = \max\{|\lambda| \mid \lambda \text{ ist Eigenwert von } P \text{ und } \lambda \neq 1\}$.
- ▶ Eben bewiesen:
 - ▶ für ergodische Markov-Ketten: $\lambda_{max} \leq 1$.
 - ▶ für reversible Markov-Ketten: $\lambda_{max} = \max\{|\lambda_2|, |\lambda_N|\} < 1$

Bemerkung

Falls $\lambda_N < 0$:

- ▶ Gehe von \mathbf{P} zu $\mathbf{P}' = \frac{1}{2}(\mathbf{P} + \mathbf{I})$ über.
- ▶ Eigenwerte $\lambda'_i = \frac{1}{2}(\lambda_i + 1) > 0$, also
- ▶ $\lambda_{max} = \lambda_2$

Überblick

Anmerkungen zu Eigenwerten

Konvergenzverhalten ergodischer Markov-Ketten

Schnell mischende Markov-Ketten

Definition

- ▶ Für zwei Verteilungen \mathbf{p} und \mathbf{q} ist die *totale Variationsdistanz*

$$\|\mathbf{p} - \mathbf{q}\|_{tv} = \frac{1}{2} \sum_{j \in S} |\mathbf{p}_j - \mathbf{q}_j| .$$

- ▶ Übung:

$$\|\mathbf{p} - \mathbf{q}\|_{tv} = \max_{T \subseteq S} |\mathbf{p}(T) - \mathbf{q}(T)|$$

wobei $\mathbf{p}(T) = \sum_{j \in T} \mathbf{p}_j$

- ▶ also $0 \leq \|\mathbf{p} - \mathbf{q}\|_{tv} \leq 1$

Definition

- ▶ ergodische Markov-Kette \mathbf{P} , stationäre Verteilung \mathbf{w} ;
für alle Verteilungen \mathbf{p} sei

$$\delta_{\mathbf{p}}(t) = \|\mathbf{p}\mathbf{P}^t - \mathbf{w}\|_{tv}$$

- ▶ Die *Variationsdistanz zum Zeitpunkt t* ist

$$\Delta(t) = \max_{\mathbf{p}} \delta_{\mathbf{p}}(t) .$$

- ▶ Übung: Maximum für einen Einheitsvektor

$$\Delta(t) = \max_i \|\mathbf{P}_i^t - \mathbf{w}\|_{tv}$$

wobei \mathbf{P}_i^t die i -te Zeile von \mathbf{P}^t ist.

- ▶ klar: $\lim_{t \rightarrow \infty} \Delta(t) = 0$ aber: *Wie schnell geht das?*

Satz

ergodische Markov-Kette, Matrix \mathbf{P} , stationäre Verteilung \mathbf{w}

Es existieren Konstanten C und $\alpha < 1$ mit

$$\Delta(t) = \max_i \|\mathbf{P}_i^t - \mathbf{w}\|_{tv} \leq C\alpha^t$$

Beweis (1)

- ▶ \mathbf{P}^{t_0} enthalte nur positive Werte
- ▶ \mathbf{W} wie bisher
- ▶ dann existiert $0 < \delta < 1$ so, dass für alle i und j gilt: $\mathbf{P}_{ij}^{t_0} \geq \delta \mathbf{w}_j$
- ▶ $\vartheta = 1 - \delta$
- ▶ \mathbf{Q} Matrix mit

$$\mathbf{P}^{t_0} = (1 - \vartheta)\mathbf{W} + \vartheta\mathbf{Q}$$

\mathbf{Q} ist zeilenstochastisch

- ▶ für jedes $k \in \mathbb{N}_0$ gilt:
 - ▶ $\mathbf{Q}^k \mathbf{W} = \mathbf{W}$ denn mit \mathbf{Q} ist auch \mathbf{Q}^k zeilenstochastisch
 - ▶ $\mathbf{W} \mathbf{P}^{t_0} = \mathbf{W}$ denn \mathbf{w} ist stationäre Verteilung

Beweis (2)

nun induktiv: für jedes $k \in \mathbb{N}_+$ ist $\mathbf{P}^{t_0 k} = (1 - \vartheta^k)\mathbf{W} + \vartheta^k \mathbf{Q}^k$

- ▶ $k = 1$: Definition von \mathbf{Q}
- ▶ $k \rightsquigarrow k + 1$:

$$\mathbf{P}^{t_0(k+1)} = \mathbf{P}^{t_0 k} \mathbf{P}^{t_0}$$

$$= \left((1 - \vartheta^k)\mathbf{W} + \vartheta^k \mathbf{Q}^k \right) \mathbf{P}^{t_0}$$

Ind.vor.

$$= (1 - \vartheta^k)\mathbf{W}\mathbf{P}^{t_0} + \vartheta^k \mathbf{Q}^k \mathbf{P}^{t_0}$$

$$= (1 - \vartheta^k)\mathbf{W} + \vartheta^k \mathbf{Q}^k \mathbf{P}^{t_0}$$

vorige Folie

$$= (1 - \vartheta^k)\mathbf{W} + \vartheta^k \mathbf{Q}^k \left((1 - \vartheta)\mathbf{W} + \vartheta \mathbf{Q} \right)$$

Ind.anf.

$$= (1 - \vartheta^k)\mathbf{W} + \vartheta^k (1 - \vartheta) \mathbf{Q}^k \mathbf{W} + \vartheta^{k+1} \mathbf{Q}^{k+1}$$

$$= (1 - \vartheta^k)\mathbf{W} + \vartheta^k (1 - \vartheta) \mathbf{W} + \vartheta^{k+1} \mathbf{Q}^{k+1}$$

vorige Folie

$$= (1 - \vartheta^{k+1})\mathbf{W} + \vartheta^{k+1} \mathbf{Q}^{k+1}$$

Beweis (3)

- ▶ $\mathbf{P}^{t_0 k} = (1 - \vartheta^k) \mathbf{W} + \vartheta^k \mathbf{Q}^k$ also
- ▶ $\mathbf{P}^{t_0 k + j} - \mathbf{W} = \vartheta^k (\mathbf{Q}^k \mathbf{P}^j - \mathbf{W})$
- ▶ Zeile i : $\|\mathbf{P}_i^{t_0 k + j} - \mathbf{w}\|_{tv} \leq \vartheta^k$
- ▶ für beliebiges $t = t_0 k + j$ mit $k = t \operatorname{div} t_0$ und $j = t \bmod t_0$

$$\begin{aligned}
 \|\mathbf{P}_i^t - \mathbf{w}\|_{tv} &= \|\mathbf{P}_i^{t_0 k + j} - \mathbf{w}\|_{tv} \\
 &\leq \vartheta^k \\
 &= \frac{1}{\vartheta} \left(\vartheta^{1/t_0}\right)^{t_0} \left(\vartheta^{1/t_0}\right)^{t_0 k} \\
 &\leq \frac{1}{\vartheta} \left(\vartheta^{1/t_0}\right)^{j + t_0 k} && \text{da } j < t_0 \text{ und } \vartheta < 1 \\
 &= \frac{1}{\vartheta} \left(\vartheta^{1/t_0}\right)^t
 \end{aligned}$$

Mitteilung (ohne Beweis)

Satz

Für reversible Markov-Kette mit stationärer Verteilung \mathbf{w} gilt:

$$\Delta(t) \leq \frac{\lambda_{max}^t}{w_{min}} .$$

dabei sei $w_{min} = \min_j w_j$

Überblick

Anmerkungen zu Eigenwerten

Konvergenzverhalten ergodischer Markov-Ketten

Schnell mischende Markov-Ketten

Definition

ergodische Markov-Kette mit stationärer Verteilung w
für $\varepsilon > 0$ definiere ihre *ε -Konvergenzzeit*:

$$\tau(\varepsilon) = \min\{t \mid \forall t' \geq t : \Delta(t') \leq \varepsilon\}$$

- ▶ engl. *mixing time*
- ▶ falls kein ε explizit angegeben: $1/4$

Von Probleminstanzen zu Markovketten

mitunter vorliegende Situation

- ▶ gegeben: unendliche Menge von «Probleminstanzen» I
- ▶ zu jedem I wird eine Markovkette $M(I)$ konstruiert

Beispiel:

- ▶ I : Graph (V, E)
- ▶ $M(I)$: Markovkette mit
 - ▶ Zustände: Matchings in I
 - ▶ Übergangswahrscheinlichkeiten für Matching m :
wähle zufällig gleichverteilt eine Kante $e \in E$
 - ▶ mit W.keit $1/2$ kein Übergang
 - ▶ mit W.keit $1/2$ Übergang zu

$$m' = \begin{cases} m - e, & \text{falls } e \in m \\ m + e, & \text{falls } e \notin m \text{ und } m + e \text{ Matching} \\ m, & \text{sonst} \end{cases}$$

Definition

Familie $M(I)$ von Markovketten heißt *schnell mischend*, falls die ε -Konvergenzzeit polynomiell in $|I|$ und $\ln 1/\varepsilon$ ist.

Rechnung

reversible Markov-Kette jedenfalls dann schnell mischend,
wenn für ein t , das polynomiell in $|I|$ und $\log 1/\varepsilon$ ist, gilt

$$\frac{\lambda_{max}^t}{w_{min}} \leq \varepsilon$$

Rechnung (2)



$$\left(\frac{1}{\lambda_{\max}}\right)^t \geq \frac{1}{\varepsilon w_{\min}}$$

$$t \geq \frac{\ln \varepsilon^{-1} + \ln w_{\min}^{-1}}{\ln \lambda_{\max}^{-1}}$$

- ▶ Wegen $1 - x \leq \ln x^{-1}$ für $0 < x < 1$ ist dafür hinreichend:

$$t \geq \frac{\ln \varepsilon^{-1} + \ln w_{\min}^{-1}}{1 - \lambda_{\max}}$$

- ▶ schnelles Mischen, falls $\ln w_{\min}^{-1}$ und $1/(1 - \lambda_{\max})$ polynomiell in $|I|$

Satz

(ohne Beweis)

Für reversible Markov-Ketten gilt:

$$\tau(\varepsilon) \leq \frac{1}{1 - \lambda_{max}} \log \frac{1}{w_{min}\varepsilon}$$

$$\tau(\varepsilon) \geq \frac{1}{2(1 - \lambda_{max})} \log \frac{1}{2\varepsilon}$$

Woher bekommt man λ_{max} ?

Definition

- ▶ reversible Markov-Kette $M = (S, \mathbf{P})$, stationäre Verteilung \mathbf{w}
- ▶ sei F_M der gerichtete kantengewichtete Graph mit
 - ▶ Knotenmenge S und
 - ▶ Kantenmenge $E_F = \{(i, j) \mid i \neq j \wedge P_{ij} > 0\}$.
- ▶ jede Kante (i, j) gewichtet mit Zahl $c(i, j) = \mathbf{w}_i P_{ij}$.

Definition

- ▶ Für reversible Markov-Kette mit Zustandsmenge S und stationärer Verteilung \mathbf{w}
- ▶ definiere für jede Teilmenge $T \subseteq S$

$$\text{die Kapazität} \quad C(T) = \sum_{i \in T} \mathbf{w}_i$$

$$\text{den Fluß} \quad F(T) = \sum_{i \in T, j \notin T} \mathbf{w}_i P_{ij}$$

$$\text{und} \quad \Phi(T) = F(T)/C(T)$$

- ▶ Der *Leitwert* Φ der Markov-Kette ist dann

$$\Phi = \min_{T \subseteq S} \max\{\Phi(T), \Phi(S \setminus T)\} = \min_{T \subseteq S, 0 < C(T) \leq 1/2} \Phi(T) .$$

Satz

Für jede reversible Markov-Kette gilt:

$$1 - 2\Phi^2 \leq \lambda_2 \leq 1 - \frac{\Phi^2}{2} .$$

Korollar

Für reversible Markov-Ketten (mit $\lambda_2 = \lambda_{max}$) ist

$$\tau(\varepsilon) \leq \frac{2}{\Phi^2} (\ln \varepsilon^{-1} + \ln w_{min}^{-1})$$

Woher bekommt man Φ ?

Definition

- ▶ für Paar (i, j) von Knoten in F_M soll
- ▶ von einem „Gut“ g_{ij} die Menge $\mathbf{w}_i \mathbf{w}_j$ von i nach j transportiert werden.
- ▶ gesucht: Flüsse $f_{ij} : E_F \rightarrow \mathbb{R}_+$, so dass gilt:

$$\sum_k f_{ij}(i, k) = \mathbf{w}_i \mathbf{w}_j$$

für alle $\ell \neq i, j$: $\sum_k f_{ij}(k, \ell) = \sum_m f_{ij}(\ell, m)$

$$\sum_k f_{ij}(k, j) = \mathbf{w}_i \mathbf{w}_j$$

Definition (2)

- ▶ Gesamtfluss durch eine Kante e sei

$$f(e) = \sum_{i \neq j} f_{ij}(e)$$

und

- ▶ die *relative Kantenauslastung*

$$\rho(f) = \max_{e \in E_F} f(e)/c(e)$$

mit $c((i, j)) = \mathbf{w}_i \mathbf{P}_{ij}$

Lemma

(ohne Beweis)

Für jede Markov-Kette mit Flüssen f_{ij} gilt:

$$\Phi \geq \frac{1}{2\rho(f)} .$$

Beispiel: Hyperwürfel

- ▶ reversible Markov-Kette $M_{G,\beta}$ wie in Kapitel 9 für Hyperwürfel H_n der Dimension n mit $\beta = 1/2$.
- ▶ $\mathbf{P}_{ii} = 1/2$ und $\mathbf{P}_{ij} = 1/2n$ für $i \neq j$.
- ▶ stationäre Verteilung
 - ▶ Gleichverteilung mit $w_{min} = 1/2^n$
 - ▶ also $\log 1/w_{min} = n$ polynomiell in n
- ▶ Schnelles Mischen: Suche Flüsse f_{ij}
 - ▶ die $1/2^{2n}$ transportieren und
 - ▶ kleine Kantenauslastung erzeugen.

Beispiel: Hyperwürfel (2)

- ▶ Wähle: gleichmäßige Verteilung auf alle $d!$ kürzeste Pfade zwischen i und j ($d = \text{Hammingdistanz}$)
- ▶ Aus Symmetriegründen gleicher Gesamtfluss auf jeder Kante.
- ▶ Für jedes d gibt es $2^n \cdot \binom{n}{d}$ Paare (i, j) mit Abstand d .
- ▶ Für ein festes Paar (i, j) haben alle für den Fluss f_{ij} verwendeten Pfade Länge d . Also:

$$\sum_{e \in E_F} f_{ij}(e) = d \mathbf{w}_i \mathbf{w}_j .$$

Beispiel: Hyperwürfel (3)

$$\begin{aligned} f(e) &= \frac{1}{|E_F|} \sum_{d=1}^n 2^n \binom{n}{d} \cdot d \cdot \mathbf{w}_i \mathbf{w}_j \\ &= \frac{1}{n2^n} \sum_{d=1}^n 2^n \binom{n}{d} \cdot d \cdot \frac{1}{2^{2n}} \\ &= \frac{1}{2^{2n}} \sum_{d=1}^n \binom{n}{d} \cdot \frac{d}{n} \\ &= \frac{1}{2^{2n}} \sum_{d=1}^n \binom{n-1}{d-1} = \frac{1}{2^{2n}} \sum_{d=0}^{n-1} \binom{n-1}{d} \\ &= \frac{2^{n-1}}{2^{2n}} = \frac{1}{2 \cdot 2^n} \end{aligned}$$

Beispiel: Hyperwürfel (4)

- ▶ eben: $f(e) = 1/(2 \cdot 2^n)$.
- ▶ andererseits $c(e) = \mathbf{w}_i \mathbf{P}_{ij} = 1/(2n \cdot 2^n)$
- ▶ also $\rho(f) = \frac{1/(2 \cdot 2^n)}{1/(2n \cdot 2^n)} = n$
- ▶ daher $\Phi \geq \frac{1}{2\rho(f)} = \frac{1}{2n}$
- ▶ daher $1 - \frac{1}{2n^2} \leq \lambda_2 \leq 1 - \frac{1}{8n^2}$
- ▶ also $1/(1 - \lambda_2) \in \Theta(n^2)$
- ▶ zusammen mit $\ln w_{\min}^{-1} = n$
- ▶ Korollar von vorhin: Markov-Kette schnell mischend

Zusammenfassung

- ▶ bei schnellem Mischen geht es um ganze Familien von Markov-Ketten (passend zu von Probleminstanzen)
 - ▶ und nicht um eine einzelne Markov-Kette
- ▶ Kriterien, um festzustellen, ob sie schnell mischend sind