

# Stochastik für die Informatik, Vorlesung 24

## Inhalt

- ▶ Konvergenz gegen die invariante Verteilung
- ▶ Anwendungen des Konvergenztheorems
- ▶ Einführung in die Informationstheorie, Präfixcodes

## Lernziele

- ▶ Die Bedeutung von invarianten Verteilungen kennen
- ▶ Anwendungen des Konvergenztheorems kennen

**Vorkenntnisse:** Markovketten, stochastische Matrizen, Matrizenrechnung, lineare Algebra.

# Konvergenz gegen die invariante Verteilung

(Theorem 11.7) Sei  $(X_i)_{i \in \mathbb{N}_0}$  eine **irreduzible und aperiodische** homogene Markov-Kette mit Zustandsraum  $S$ . Sei  $(\pi_a)_{a \in S}$  eine invariante Verteilung. Dann gilt für alle  $a \in S$ , unabhängig von der Startverteilung,

$$\lim_{n \rightarrow \infty} \mathbb{P}(X_n = a) = \pi_a.$$

- ▶ Egal wo man startet: Für große  $n$  gilt  $\mathbb{P}(X_n = a) \approx \pi_a$ .
- ▶ Falls die Kette in einer (beliebigen) Startverteilung  $\nu$  startet, befindet sie sich nach hinreichend langer Zeit in der stationären Verteilung
- ▶ Information über Struktur der Kette. Bsp. Netzwerk: Knoten mit vielen Kanten werden oft besucht, für solche Knoten  $a$  ist  $\pi_a$  größer als für solche die selten besucht werden.

# Konvergenz gegen die invariante Verteilung

(Theorem 11.7) Sei  $(X_i)_{i \in \mathbb{N}_0}$  eine **irreduzible und aperiodische** homogene Markov-Kette mit Zustandsraum  $S$ . Sei  $(\pi_a)_{a \in S}$  eine invariante Verteilung. Dann gilt für alle  $a \in S$ , unabhängig von der Startverteilung,

$$\lim_{n \rightarrow \infty} \mathbb{P}(X_n = a) = \pi_a.$$

- ▶ Egal wo man startet: Für große  $n$  gilt  $\mathbb{P}(X_n = a) \approx \pi_a$ .
- ▶ Falls die Kette in einer (beliebigen) Startverteilung  $\nu$  startet, befindet sie sich nach hinreichend langer Zeit in der stationären Verteilung
- ▶ Information über Struktur der Kette. Bsp. Netzwerk: Knoten mit vielen Kanten werden oft besucht, für solche Knoten  $a$  ist  $\pi_a$  größer als für solche die selten besucht werden.

## Beispiel 11.13 Warteschlangen

- ▶ Zeitabschnitte von fester Länge
- ▶ Parameter  $k \in \mathbb{N}, \mu \in [0, 1], \lambda \in [0, 1]$ , mit  $\lambda + \mu \leq 1$ .
- ▶ In jedem Zeitabschnitt geschieht **eines** der folgenden Ereignisse:
  - ▶ Falls weniger als  $k$  Kunden da sind, so kommt ein neuer Kunde mit Wahrscheinlichkeit  $\lambda$  an
  - ▶ Falls mindestens ein Kunde da ist, so verlässt ein Kunde die Schlange mit Wahrscheinlichkeit  $\mu$
  - ▶ Andernfalls geschieht nichts
- ▶  $X_n :=$  Anzahl Kunden in der Schlange im  $n$ -ten Zeitabschnitt
- ▶  $(X_n)_{n \in \mathbb{N}_0}$  ist Markov-Kette mit Zustandsraum  $S = \{0, \dots, k\}$

# Beispiel 11.13 Warteschlangen

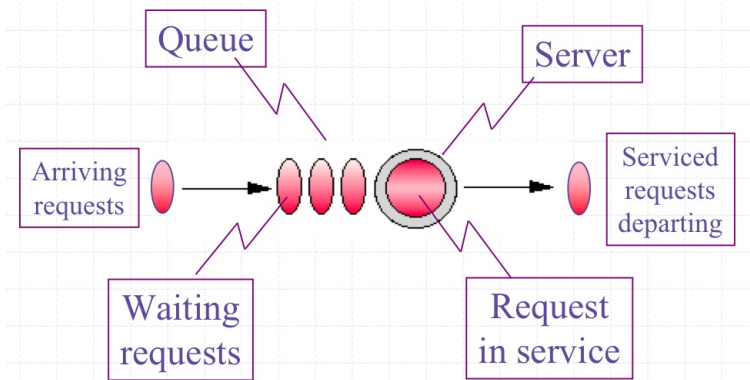


Bild: <http://www.perfdynamics.com/>

## Beispiel 11.13 Warteschlangen

Mögliche Übergänge:

$$p_{i,i+1} = \lambda \text{ falls } i < k$$

$$p_{i,i-1} = \mu \text{ falls } i > 0.$$

d.h.

$$P = \begin{bmatrix} 1 - \lambda & \lambda & 0 & \dots & \dots & 0 \\ \mu & 1 - \mu - \lambda & \lambda & 0 & \dots & 0 \\ 0 & \mu & 1 - \mu - \lambda & \lambda & 0 & \dots & 0 \\ \vdots & & \ddots & \ddots & \ddots & & \vdots \\ 0 & \dots & & & 0 & \mu & 1 - \mu - \lambda & \lambda \\ 0 & \dots & & & & 0 & \mu & 1 - \mu \end{bmatrix}$$

Frage: Wie viele Kunden sind auf lange Sicht in der Schlange?

Stabilität für  $k \rightarrow \infty$ ?

## Beispiel 11.13 Warteschlangen

Mögliche Übergänge:

$$p_{i,i+1} = \lambda \text{ falls } i < k$$

$$p_{i,i-1} = \mu \text{ falls } i > 0.$$

d.h.

$$P = \begin{bmatrix} 1 - \lambda & \lambda & 0 & \dots & \dots & 0 \\ \mu & 1 - \mu - \lambda & \lambda & 0 & \dots & 0 \\ 0 & \mu & 1 - \mu - \lambda & \lambda & 0 & \dots & 0 \\ \vdots & & \ddots & \ddots & \ddots & & \vdots \\ 0 & \dots & & & 0 & \mu & 1 - \mu - \lambda & \lambda \\ 0 & \dots & & & & 0 & \mu & 1 - \mu \end{bmatrix}$$

**Frage:** Wie viele Kunden sind auf lange Sicht in der Schlange?

**Stabilität** für  $k \rightarrow \infty$ ?

## Beispiel 11.13 Warteschlangen

(Satz 11.9) Die invariante Verteilung der beschriebenen Warteschlange ist gegeben durch

$$\pi_i = \frac{1}{\sum_{j=0}^k (\lambda/\mu)^j} \cdot \left(\frac{\lambda}{\mu}\right)^i, \quad i = 0, \dots, k$$

Was passiert für  $k \rightarrow \infty$ ?

- ▶ Falls  $\lambda/\mu < 1$  ist, gilt  $\sum_{j=0}^{\infty} \left(\frac{\lambda}{\mu}\right)^j = \frac{\mu}{\mu-\lambda} < \infty$ , die Warteschlange hat für  $k \rightarrow \infty$  eine invariante Verteilung, ist **stabil**
- ▶ Andernfalls ist  $\sum_{j=0}^{\infty} \left(\frac{\lambda}{\mu}\right)^j = \infty$ , die Warteschlange ist instabil



# Kapitel 16: Markov-Ketten Monte Carlo (MCMC)

**Ziel:** Simulation aus einer vorgegebenen Verteilung  $\pi = (\pi_x)_{x \in S}$ .

**Grundidee:** Konstruiere eine Markov-Kette  $X = (X_n)_{n \in \mathbb{N}}$ , welche  $\pi$  als **invariante Verteilung** hat. Lasse dann die Markov-Kette **lange genug** laufen. Nach  $n$  Schritten, für  $n$  hinreichend groß, hat nach dem Satz auf der letzten Folie  $X_n$  annähernd die Verteilung  $\pi$ .

- ▶ Konkrete Konstruktion einer solchen Kette?
- ▶ Benötigte Zeit für die Konvergenz?

# Metropolis-Algorithmus

(Metropolis-Hastings-Algorithmus, Simulated Annealing)

**Fragestellung:** Konstruktion einer Markov-Kette auf einem endlichen Zustandsraum  $S$  mit invarianter Verteilung  $\pi$ .

**Vorgehen:** Zweistufiges Verfahren

1. Konstruiere eine einfache **Referenzkette**, welche zulässige Übergänge **vorschlägt**
2. **Entscheide** bei jedem vorgeschlagenen Übergang, ob er tatsächlich ausgeführt wird oder nicht. Dabei sollen Übergänge welche in einen Zustand mit **höherer Wahrscheinlichkeit bezüglich  $\pi$**  führen, bevorzug ausgeführt werden.

# Metropolis-Algorithmus

Gegeben Verteilung  $\pi$  auf endlicher Menge  $S$ . Ziel: Simulation aus dieser Verteilung.

Algorithmus:

- ▶ Sei  $Q = (q_{k,l})_{k,l \in S}$  eine beliebige Übergangsmatrix auf  $S$ . Die zugehörige Markov-Kette ist die Referenzkette.
- ▶ Definiere eine neue Übergangsmatrix  $P = (p_{k,l})_{k,l \in S}$  mit Hilfe von  $Q$  als

$$p_{k,l} = q_{k,l} \cdot \min\left(1, \frac{\pi(l)q_{lk}}{\pi(k)q_{kl}}\right) \quad \text{falls } k \neq l$$

und  $p_{k,k} = 1 - \sum_{l \neq k} p_{k,l}$  sonst.

- ▶ Starte eine Markov-Kette in einem beliebigen Punkt von  $S$ , und führe Übergänge entsprechend der Matrix  $P$  aus.

# Metropolis-Algorithmus

- ▶  $Q$  schlägt Übergänge vor, welche mit Wahrscheinlichkeit  $\min\left(1, \frac{\pi(l)q_{lk}}{\pi(k)q_{kl}}\right)$  tatsächlich ausgeführt werden
- ▶  $\pi$  ist invariante Verteilung für  $P$  (Beweis)
- ▶ (Satz 16.3) Falls  $P$  irreduzibel und aperiodisch ist, konvergiert die Markov-Kette gegen die gesuchte Verteilung  $\pi$  (Monte-Carlo-Simulation)
- ▶ Konkrete Berechnung: Braucht die **Verhältnisse**  $\pi(l)q_{lk}/\pi(k)q_{kl}$  zu kennen, aber nicht die einzelnen Werte
- ▶ Wahl von  $Q$  kann geschickt ans Problem angepasst werden
- ▶ **Verbleibende Frage:** Wie lange muss man die Markov-Kette laufen lassen, um eine vernünftige Genauigkeit zu erreichen?

## Beispiel 16.1: Simulation bedingter Verteilungen

- ▶ **Gegeben:**  $Y_1, \dots, Y_N$  unabhängige, identisch verteilte, diskrete Zufallsvariablen mit **bekannter Verteilung**  $r_i, i \in \mathbb{N}_0$ .
- ▶ **Gesucht:** **Bedingte Verteilung** von  $(Y_1, \dots, Y_N)$  **gegeben**  $Y_1 + \dots + Y_N = M$ , für ein vorgegebenes  $M \in \mathbb{N}$ .
- ▶ **Notation:** Für  $k = (k_1, \dots, k_N) \in \mathbb{N}_0^N$  schreibe

$$\pi(k) := \mathbb{P}(Y_1 = k_1, \dots, Y_N = k_N \mid Y_1 + \dots + Y_N = M)$$

für die gesuchte bedingte Verteilung von  $Y_1, \dots, Y_N$  gegeben  $Y_1 + \dots + Y_N = M$  (abhängig von  $N$  und  $M$ , und der Verteilung  $r_i, i \in \mathbb{N}_0$ ).

## Beispiel: Simulation bedingter Verteilungen

In der Situation der letzten Folie hat die gesuchte Verteilung  $\pi$  die Form

$$\pi(k) = \frac{1}{C(N, M)} \cdot r_{k_1} \cdot \dots \cdot r_{k_N},$$

für  $k = (k_1, \dots, k_N) \in \mathbb{N}_0^N, k_1 + \dots + k_N = M$

- ▶ Da im Metropolis-Algorithmus nur die Verhältnisse  $\pi(k)/\pi(l)$  auftreten, braucht man  $C(N, M)$  nicht zu bestimmen
- ▶ (Konstruiere die Referenzkette)
- ▶ (Konstruiere die Metropolis-Kette)

# Konvergenzgeschwindigkeit

- ▶ Aus dem Theorem über die Konvergenz einer (irreduzibler und aperiodischer) Markov-Kette  $(X_n)_{n \in \mathbb{N}}$  gegen ihre invariante Verteilung  $\pi$  wissen wir: Für jedes  $a \in S$  und für große  $n$  gilt

$$\mathbb{P}(X_n = a) \approx \pi(a).$$

- ▶ Frage: Wie kann man **große  $n$**  und  $\approx$  quantifizieren?

# Konvergenzgeschwindigkeit

(Def. 16.1) Sei  $(X_n)_{n \in \mathbb{N}_0}$  eine Markov-Kette mit invarianter Verteilung  $\{\pi_a\}_{a \in S}$ . Die  $\varepsilon$ -Mischzeit  $\tau(\varepsilon)$  der Kette ist definiert als das kleinste  $n > 0$  so dass für alle  $a \in S$  und für beliebige Startverteilung gilt:

$$|\mathbb{P}(X_n = a) - \pi(a)| \leq \varepsilon.$$

- ▶ In Worten: Für  $n = \tau(\varepsilon)$  ist der Abstand von der invarianten Verteilung höchstens  $\varepsilon$ .
- ▶ Man kann sogar beweisen: Für alle  $n$  welche größer sind als die  $\varepsilon$ -Mischzeit ist der Abstand von der invarianten Verteilung höchstens  $\varepsilon$ .
- ▶ Oft auch:  $\varepsilon = 1/4$  fest gewählt.
- ▶ Berechnung der Mischzeit?



# Spektrallücke

(Satz 16.2) Sei  $S$  eine endliche Menge mit  $|S| = N$ . Sei  $P$  die Übergangsmatrix einer irreduziblen, aperiodischen Markov-Kette auf  $S$ . Dann sind alle **Eigenwerte** dieser Matrix reell und dem Betrag nach kleiner oder gleich 1.

(Ohne Beweis)

(Def. 16.2) Sei  $\lambda^*$  der **dem Betrage nach größte Eigenwert** von  $P$ , welcher  $\neq 1$  ist. Dann heißt

$$\gamma^* := 1 - |\lambda^*|$$

die **Spektrallücke** von  $P$  (bzw. der zugehörigen Markov-Kette).

## Spektrallücke und Mischzeit

(Satz 16.3) Sei  $(X_n)_{n \in \mathbb{N}}$  eine Markov-Kette auf einem **endlichen** Zustandsraum  $S$ , mit Übergangsmatrix  $P$  und invarianter Verteilung  $\{\pi_a\}_{a \in S}$ , welche zusätzlich  $\pi_a p_{a,b} = \pi_b p_{b,a}$  für alle  $a, b$  erfüllt. Sei  $\bar{\pi}$  das kleinste  $\pi_a, a \in S$ . Für die  $\varepsilon$ -Mischzeit gilt dann

$$\tau(\varepsilon) \leq \log(1/(\bar{\pi}\varepsilon)) \cdot \frac{1}{\gamma^*}.$$

(Ohne Beweis)

- ▶ Daraus folgt insbesondere für  $a \in S, n \in \mathbb{N}$

$$|P(X_n = a) - \pi_a| \leq \frac{1}{\bar{\pi}} e^{-\gamma^* n}$$

- ▶ Je größer die Spektrallücke, desto schneller konvergiert die Markov-Kette gegen die invariante Verteilung.

# Spektrallücke und Mischzeit

- ▶ Um die Aussage  $\mathbb{P}(X_n = a) \approx \pi(a)$  präzise zu machen, geht man also folgendermaßen vor:
  - ▶ Wähle die Präzision  $\varepsilon$ .
  - ▶ Berechne  $\pi$  und untersuche ob die zusätzliche Bedingung erfüllt ist.
  - ▶ Berechne die Eigenwerte von  $P$ .
  - ▶ Berechne  $\bar{\pi}$  und die Spektrallücke  $\gamma^*$ .
  - ▶ Dann gilt für alle  $n \geq \log(1/(\bar{\pi}\varepsilon)) \frac{1}{\gamma^*}$ , dass

$$|\mathbb{P}(X_n = a) - \pi(a)| \leq \varepsilon$$

für alle  $a$  und jede Startverteilung gilt.

- ▶ Anwendung: Simulation von Verteilungen mit einer vorgegebenen Präzision.
- ▶ Die Bestimmung von  $\pi$  und  $\gamma^*$  ist ein einfaches Problem der linearen Algebra.

# Kapitel X: Informationstheorie

**Literatur:** G. Kersting, A. Wakolbinger: Elementare Stochastik;  
Kapitel VI: Ideen aus der Informationstheorie.

Verfügbar in der Bibliothek, auch als E-Book.

**Inhalt:** Stochastische Aspekte der Informationsübermittlung:  
Codierung, Redundanz, Entropie...

# Grundbegriffe

- ▶ Ein **Alphabet** ist eine höchstens abzählbare Menge  $S$ .
- ▶ Ein **Buchstabe** ist ein Element eines Alphabets.
- ▶ Ein **binärer Code** ist eine *injektive* Abbildung

$$k : S \rightarrow \bigcup_{l \geq 1} \{0, 1\}^l,$$

also eine Abbildung, die jedem Buchstaben  $a \in S$  eine Folge  $k(a) = k_1(a), \dots, k_l(a)$  der **Länge**  $l = \ell(a)$  mit Folgengliedern  $k_i(a) \in \{0, 1\}$  als **Codewort** zuordnet.

# Präfixcodes

Länge als Maß für die Güte des Codes: Möglichst kurz, aber auch leicht zu entschlüsseln

- ▶ Ein **Präfixcode** ist ein binärer Code, bei dem kein Codewort Anfangsstück eines anderen Codeworts ist. Das bedeutet: Für  $a, b \in S$  mit  $a \neq b$  gibt es *keine* Folge  $f = (f_1, \dots, f_m) \in \{0, 1\}^m$  mit  $k(a)f = k(b)$ .
- ▶ (Code als Fragestrategie)
- ▶ (Baumdarstellung)

# Fano-Kraft-Ungleichung

(Satz) Sei  $k$  ein Präfixcode für ein Alphabet  $S$ . Sei  $\ell(a)$  die Länge des Codewortes von  $a \in S$ . Dann gilt

$$\sum_{a \in S} 2^{-\ell(a)} \leq 1$$

- ▶ (Beweis)
- ▶ (Gleichheit, strikte Ungleichheit)