

# 7. Markov-Ketten

Benannt nach Andrei A. Markov [1856-1922]

Einige Stichworte:

- Markov-Ketten
  - ▶ Definition
  - ▶ Eigenschaften
  - ▶ Konvergenz
- Hidden Markov Modelle
  - ▶ Motivation und Inferenz
  - ▶ Baum-Welch-Algorithmus
  - ▶ Viterbi-Algorithmus

## 7.1 Definition und Eigenschaften von Markov-Ketten

Sei  $\mathbf{X} = (X_0, X_1, X_2, \dots)$  eine Folge von diskreten Zufallsvariablen, die alle Ausprägungen in einer endlichen bzw. abzählbaren Menge  $S$  haben.

$S$  heißt der **Zustandsraum** und  $s \in S$  ein **Zustand**.

$\mathbf{X}$  heißt **Markov-Kette** (MK), falls

$$\begin{aligned} & P(X_n = s | X_0 = x_0, X_1 = x_1, \dots, X_{n-1} = x_{n-1}) \\ &= P(X_n = s | X_{n-1} = x_{n-1}) \end{aligned}$$

für alle  $n \geq 1$  und alle  $s, x_0, x_1, \dots, x_{n-1} \in S$ .

# Interpretation

Bedingt auf die gesamte Vergangenheit  $X_0, X_1, \dots, X_{n-1}$  des Prozesses  $\mathbf{X}$  hängt  $X_n$  nur vom letzten Wert  $X_{n-1}$  ab.

Darstellung mit Pfeilen in einem **graphischen Modell**:

$$X_0 \rightarrow X_1 \rightarrow X_2 \rightarrow \dots \rightarrow X_{n-1} \rightarrow X_n$$

Anders ausgedrückt:

**Bedingt** auf die **Gegenwart** ( $X_{n-1}$ ) ist die **Zukunft** des Prozesses ( $X_n, X_{n+1}, \dots$ ) **unabhängig** von seiner **Vergangenheit** ( $X_0, X_1, \dots, X_{n-2}$ ).

→ Begriff der **bedingten Unabhängigkeit**

# Bedingt unabhängige Zufallsvariablen

Zwei diskrete Zufallsvariablen  $X$  und  $Y$  heißen **bedingt unabhängig** gegeben  $Z$ , wenn für die entsprechend definierten Wahrscheinlichkeitsfunktionen gilt:

$$f_{X,Y|Z}(x,y|z) = f_{X|Z}(x|z) \cdot f_{Y|Z}(y|z)$$

für alle  $x$ ,  $y$  und  $z$ .

# Übergangswahrscheinlichkeiten

Die Entwicklung einer Markov-Kette  $\mathbf{X}$  ist gekennzeichnet durch die (Ein-Schritt) **Übergangswahrscheinlichkeiten**

$$P(X_{n+1} = j | X_n = i)$$

für alle  $i, j \in S$ .

Man nennt eine Markov-Kette **homogen**, wenn diese nicht von  $n$  abhängen und definiert

$$p_{ij} = P(X_{n+1} = j | X_n = i) = P(X_1 = j | X_0 = i)$$

für alle  $n \geq 1$  und alle  $i, j \in S$ .

# Die Übergangsmatrix

Die Werte  $p_{ij}$  werden in einer  $|S| \times |S|$ -Matrix  $\mathbf{P}$  zusammengefasst, der sogenannten **Übergangsmatrix**.  $\mathbf{P}$  beschreibt also die Kurzzeitentwicklung einer homogenen Markov-Kette  $\mathbf{X}$ .

$\mathbf{P}$  ist eine **stochastische Matrix**, d.h. sie hat folgende Eigenschaften:

- 1  $p_{ij} \geq 0$  für alle  $i, j \in S$
- 2  $\sum_j p_{ij} = 1$  für alle  $i \in S \Rightarrow$  "Zeilensummen gleich eins"

# Beispiele

1.Beispiel: Telefon besetzt / frei mit  $S = \{0, 1\}$  und

$$\mathbf{P} = \begin{pmatrix} 0.9 & 0.1 \\ 0.4 & 0.6 \end{pmatrix}$$

2.Beispiel: Der Zustandsraum umfasst die vier Basen der DNA (Adenin, Cytosin, Guanin, Thymin):  $S = \{A, C, G, T\}$ .  
Die geschätzte Übergangsmatrix beim "Ablaufen" der DNA ist

$$\mathbf{P} = \begin{pmatrix} 0.300 & 0.205 & 0.285 & 0.210 \\ 0.322 & 0.298 & 0.078 & 0.302 \\ 0.248 & 0.246 & 0.298 & 0.208 \\ 0.177 & 0.239 & 0.292 & 0.292 \end{pmatrix}$$

Durbin *et al.* (1998) "Biological sequence analysis", p. 50

# Gerichtete Graphen


Der von der Markov-Kette  $\mathbf{X}$  mit Zustandsraum  $S$  und Übergangsmatrix  $\mathbf{P}$  erzeugte gerichtete Graph  $G$  besteht aus  $|S|$  Knoten und maximal  $|S|^2$  Kanten. Jeder Knoten bezieht sich auf einen Zustand und jede Kante  $(i, j)$  auf  $p_{ij}$  für  $p_{ij} > 0$ . Der Graph beschreibt also die Struktur aller direkten Verbindungen von Zustand  $i$  zu Zustand  $j \forall i, j$ .

# Darstellung von MKs mit gerichteten Graphen

Ein Zustandsraum  $S = \{A, B, C\}$  und die dazugehörige Übergangsmatrix

$$\mathbf{P} = \begin{pmatrix} 0.5 & 0 & 0.5 \\ 0.4 & 0.6 & 0 \\ 0.3 & 0.3 & 0.4 \end{pmatrix}$$

erzeugen den folgenden gerichteten Graphen:




# Darstellung von MKs mit gerichteten Graphen II

1. Beispiel: Aus Telefon besetzt / frei mit  $S = \{0, 1\}$  und

$$\mathbf{P} = \begin{pmatrix} 0.9 & 0.1 \\ 0.4 & 0.6 \end{pmatrix}$$

folgt der folgende gerichtete Graph:



# Die $n$ -Schritt-Übergangsmatrix

Die Langzeitentwicklung einer Markov-Kette  $\mathbf{X}$  ist durch die  $n$ -**Schritt-Übergangsmatrix**  $\mathbf{P}(m, m+n)$  mit Elementen

$$p_{ij}(m, m+n) = P(X_{m+n} = j | X_m = i)$$

$$\text{bzw. } p_{ij}(n) = P(X_n = j | X_0 = i)$$

gegeben, wobei die letzte Gleichung für homogene Markov-Ketten gilt. In diesem Fall ergibt sich natürlich

$$\mathbf{P}(m, m+1) = \mathbf{P}$$

und wir schreiben  $\mathbf{P}_n = \mathbf{P}(m, m+n)$ .

# Die Chapman-Kolmogorov-Gleichungen

Für eine homogene Markov-Kette  $\mathbf{X}$  gilt:

$$p_{ij}(m, m+n+r) = \sum_k p_{ik}(m, m+n)p_{kj}(m+n, m+n+r) \quad (1)$$

$$\mathbf{P}(m, m+n+r) = \mathbf{P}(m, m+n)\mathbf{P}(m+n, m+n+r) \quad (2)$$

$$\mathbf{P}_n = \mathbf{P}(m, m+n) = \mathbf{P}^n \quad (3)$$

Dabei ist (2) nur (1) in Matrizenform und (3) folgt durch Iteration.

$\mathbf{P}^n$  bezeichnet die  $n$ -te Potenz von  $\mathbf{P}$ .

Beweis zu (1) in Vorlesung.

## Fortsetzung des 1. Beispiels

Zwei-Schritt-Übergangsmatrix:

$$\mathbf{P}_2 = \mathbf{P}^2 = \begin{pmatrix} 0.9 & 0.1 \\ 0.4 & 0.6 \end{pmatrix} \begin{pmatrix} 0.9 & 0.1 \\ 0.4 & 0.6 \end{pmatrix} = \begin{pmatrix} 0.85 & 0.15 \\ 0.6 & 0.4 \end{pmatrix}$$

Zum Beispiel ist also der Eintrag  $p_{21}(2)$  in  $\mathbf{P}_2$  gleich

$$\begin{aligned} p_{21}(2) &= P(X_{n+2} = 1 | X_n = 2) \\ &= P(X_{n+1} = 2 | X_n = 2) \cdot P(X_{n+2} = 1 | X_{n+1} = 2) \\ &\quad + P(X_{n+1} = 1 | X_n = 2) \cdot P(X_{n+2} = 1 | X_{n+1} = 1) \\ &= 0.6 \cdot 0.4 + 0.4 \cdot 0.9 = 0.6 \end{aligned}$$

# Die Zeit bis zum Zustandswechsel

Eine Markov-Kette  $\mathbf{X}$  mit Übergangsmatrix  $\mathbf{P}$  sei zu einem Zeitpunkt  $t$  im Zustand  $i \in S$ .

Dann ist die Dauer bis zum nächsten Zustandswechsel  $Z_i$  geometrisch verteilt mit Parameter  $1 - p_{ii}$ .

Vergleiche: Gedächtnislosigkeit der geometrischen Verteilung:

$$P(Z_i = n + k | Z_i > n) = P(Z_i = k)$$

Nützliche Eigenschaft zum Test auf Modellanpassung:

Vergleich der beobachteten und theoretischen Dauern bis zum nächsten Zustandswechsel.

# Die Anfangsverteilung

Schließlich hat jede Markov-Kette auch eine **Anfangsverteilung** für  $X_0$ . Die entsprechende Wahrscheinlichkeitsfunktion bezeichnet man mit dem Zeilenvektor  $\boldsymbol{\mu}^{(0)}$  mit Elementen

$$\mu_i^{(0)} = P(X_0 = i).$$

Die (unbedingte) Wahrscheinlichkeitsfunktion von  $X_n$  fasst man entsprechend in dem Zeilenvektor  $\boldsymbol{\mu}^{(n)}$  zusammen und es gilt:

$$\begin{aligned}\boldsymbol{\mu}^{(m+n)} &= \boldsymbol{\mu}^{(m)} \cdot \mathbf{P}^n \quad \text{und daher} \\ \boldsymbol{\mu}^{(n)} &= \boldsymbol{\mu}^{(0)} \cdot \mathbf{P}^n\end{aligned}$$

## Folgerung

Durch  $\mu^{(0)}$  und  $\mathbf{P}$  ist also die Entwicklung einer Markov-Kette vollständig bestimmt.

Die **gemeinsame** Wahrscheinlichkeitsverteilung (wichtig für Likelihood-Inferenz!) von  $X_0, \dots, X_n$  ist gegeben durch

$$\begin{aligned} & P(X_0 = x_0, X_1 = x_1, \dots, X_n = x_n) \\ &= P(X_0 = x_0) \prod_{t=1}^n P(X_t = x_t | X_{t-1} = x_{t-1}) \\ &= \mu_{x_0}^{(0)} \prod_{t=1}^n p_{x_{t-1}, x_t} \end{aligned}$$

## Beispiel: Inzucht

Eine Pflanze mit Genotyp aus  $S = \{aa, ab, bb\}$  wird mit sich selbst gekreuzt. Die Zufallsvariable  $X_n$  gibt den Genotyp in der  $n$ -ten Generation an. Daher:

$$\mathbf{P} = \begin{pmatrix} 1 & 0 & 0 \\ \frac{1}{4} & \frac{1}{2} & \frac{1}{4} \\ 0 & 0 & 1 \end{pmatrix}$$

$$\mathbf{P}^n = \begin{pmatrix} 1 & 0 & 0 \\ \frac{1}{2} - \left(\frac{1}{2}\right)^{n+1} & \left(\frac{1}{2}\right)^n & \frac{1}{2} - \left(\frac{1}{2}\right)^{n+1} \\ 0 & 0 & 1 \end{pmatrix} \xrightarrow{n \rightarrow \infty} \begin{pmatrix} 1 & 0 & 0 \\ \frac{1}{2} & 0 & \frac{1}{2} \\ 0 & 0 & 1 \end{pmatrix}$$

$\Rightarrow$  Letztendlich bleiben nur die Genotypen  $aa$  und  $bb$  übrig, die sich dann deterministisch reproduzieren.

## Beispiel: Genhäufigkeit in Population konstanter Größe $N$

$X_n = i$ : Anzahl der Individuen einer Population mit bestimmtem Genotyp zum Zeitpunkt  $n$

Einfaches Modell:

Zu jedem Zeitpunkt stirbt ein zufällig ausgewähltes Mitglied. Das “nachrückende” Mitglied hat den Genotyp mit Wahrscheinlichkeit  $\frac{i}{N}$ .

$$\leadsto p_{ij} = \begin{cases} \frac{i(N-i)}{N^2} & \text{für } j = i \pm 1 \\ 1 - 2\frac{i(N-i)}{N^2} & \text{für } j = i \\ 0 & \text{sonst} \end{cases}$$

Beachte:  $\mathbf{P}$  ist “tridiagonal”. Formulierung beinhaltet Grenzfälle  $X_n = 0$  und  $X_n = N$ .

## Beispiel: Modelle für Epidemien → Verzweigungsprozesse

$X_n$  := Anzahl der Infizierten in einer Generation  $n$

$S = \{0, 1, \dots\}$

Idee: Jeder Infizierte “erzeugt” (unabhängig von den anderen) eine zufällige Anzahl Infizierter in der nächsten Generation mit Erwartungswert  $\lambda$ .

Die Anzahl könnte z.B. Poissonverteilt sein. Dann ist  $X_n | X_{n-1} \sim \mathcal{P}(\lambda \cdot X_{n-1})$ .

Theorem:

- Für  $\lambda < 1$  wird die Epidemie mit Wahrscheinlichkeit 1 irgendwann aussterben.
- Für  $\lambda > 1$  ist die Wahrscheinlichkeit, dass die Epidemie explodiert, echt größer 0.

## 7.2 Klassifikation von Zuständen und Markov-Ketten


Ein Zustand  $i \in S$  heißt **rekurrent** oder auch **persistent**, falls für die Rekurrenzzeit  $T_i = \min\{n : X_n = i | X_0 = i\}$  gilt

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

Wenn  $P(T_i < \infty) < 1$  heißt der Zustand **transient**. Eine Markov-Kette  $\mathbf{X}$  kehrt also in einen rekurrenten Zustand mit Wahrscheinlichkeit 1 zurück. Ein Zustand  $i$  heißt **absorbierend**, falls dieser nicht mehr verlassen werden kann, also  $p_{ij} = 1$ .


# Graphische Beispiele für Zustandsklassen

1. Die Rekurrenzenzeit von Zustand A ist  $T_A = 3$ :



Die minimale Anzahl an Schritten bis **X** von A nach A zurückkehrt ist 3.


2. Alle Zustände sind rekurrent/persistent:



Die Markov-Kette kehrt mit Wahrscheinlichkeit 1 in alle Zustände zurück.


## Graphische Beispiele für Zustandsklassen II

3. Zustand  $B$  ist transient:



Die Rückkehr nach  $B$  aus anderen Zuständen ist nicht möglich.

4. Zustand  $B$  ist absorbierend:



Die Markov-Kette verlässt den Zustand  $B$  nicht mehr.

# Beispiel

Betrachte den Poisson-Verzweigungsprozess

$$X_n | X_{n-1} \sim \mathcal{P}(\lambda \cdot X_{n-1})$$

Dann ist der Zustand 0 **rekurrent**, ja sogar **absorbierend**, da  $\mathbf{X}$  diesen Zustand nie verläßt.

Alle anderen Zustände sind **transient**.

# Die erwartete Rekurrenzeit

Man definiert die **erwartete Rekurrenzeit** eines Zustands  $i$  wie folgt:

$$\mu_i = E(T_i) = \begin{cases} \sum_n n f_i(n) & \text{falls } i \text{ rekurrent ist} \\ \infty & \text{falls } i \text{ transient ist} \end{cases}$$

mit  $f_i(n) = P(X_1 \neq i, \dots, X_{n-1} \neq i, X_n = i | X_0 = i)$ . Ein rekurrenter Zustand  $i$  heißt **nicht-leer**, falls seine erwartete Rekurrenzeit endlich ist. Ansonsten heißt er **leer**.

# Zusammenhang zu den Übergangswahrscheinlichkeiten

Ein rekurrenter Zustand  $i$  ist genau dann leer, wenn

$$p_{ii}(n) \rightarrow 0 \text{ für } n \rightarrow \infty$$

Dann gilt sogar

$$p_{ji}(n) \rightarrow 0 \text{ für } n \rightarrow \infty \text{ für alle } j \in S$$

# Die Periode

Die **Periode** eines Zustandes  $i$  ist der größte gemeinsame Teiler der Menge

$$\{n : p_{ii}(n) > 0\}$$

Man nennt den Zustand  $i$  **periodisch**, falls dessen Periode größer eins ist, ansonsten heißt  $i$  **aperiodisch**.

Haben alle Zustände einer Markov-Kette Periode 1, so heißt sie aperiodisch.


Ein Zustand  $i$  heißt **ergodisch**, falls er rekurrent, nicht-leer und aperiodisch ist. Sind alle Zustände von  $\mathbf{X}$  ergodisch, so heißt  $\mathbf{X}$  ergodisch.

# Beispiel

Eine Markov-Kette habe die Zustände  $S = \{A, B, C\}$  und folgende Übergangsmatrix:

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

$\Leftrightarrow$



Es gilt nun:

- jeder Zustand hat Periode 3
- die Markov-Kette ist nicht aperiodisch

# Irreduzible Zustände

Zustand  $j$  heißt **erreichbar** durch Zustand  $i$ , falls

$$p_{ij}(n) > 0$$

für mindestens ein  $n \in \mathbb{N}$ . (Schreibweise:  $i \rightarrow j$ )

Zwei Zustände  $i \neq j$  einer Markov-Kette **X kommunizieren** miteinander, falls die Zustände **gegenseitig erreichbar** sind, also falls

$$p_{ij}(n) > 0 \text{ und } p_{ji}(n') > 0$$

für mindestens ein  $n \in \mathbb{N}_0$  bzw.  $n' \in \mathbb{N}_0$ . (Schreibweise:  $i \leftrightarrow j$ )

Ein Zustand  $i$  kommuniziert per Definition immer mit sich selbst:  $i \leftrightarrow i$

Die angenommenen Zustände zwischen  $i$  und  $j$  werden **Pfad** genannt.

# Irreduzible Zustände II

Es gilt:

- Wenn  $i \leftrightarrow k$  und  $k \leftrightarrow j$ , dann auch  $i \leftrightarrow j$
- Ist  $i$  rekurrent und  $i \leftrightarrow j$ , so ist auch  $j$  rekurrent
- Ist  $i$  transient und  $i \leftrightarrow j$ , so ist auch  $j$  transient
- Erreichbarkeit entspricht einer Äquivalenzrelation  
⇒ Es können Äquivalenzklassen gebildet werden

Eine Menge  $C \subset S$  heißt **irreduzibel**, falls  $i \leftrightarrow j$  für alle  $i, j \in C$ . Eine

Menge  $C \subset S$  heißt **geschlossen**, falls  $p_{ij} = 0$  für alle  $i \in C$  und  $j \in \bar{C}$ .

Eine MK heißt **stark verbunden** falls  $i \leftrightarrow j$ , also wenn für mindestens ein  $n \in \mathbb{N}$  gilt:  $p_{ij}(n) > 0 \forall i, j$ .

Eine MK ist also irreduzibel, g.d.w. sie stark verbunden ist.

# Beispiele

Markov-Ketten mit reduziblem Zustandsraum  $S$


$$\mathbf{P}_1 = \begin{pmatrix} \frac{1}{2} & \frac{1}{2} & 0 \\ \frac{1}{2} & \frac{1}{2} & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad \mathbf{P}_2 = \begin{pmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ 0 & 0 & 1 \end{pmatrix}$$

Im folgenden Beispiel ist  $S$  irreduzibel:


$$\mathbf{P}_3 = \begin{pmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ 0 & \frac{1}{2} & \frac{1}{2} \end{pmatrix}$$

# Beispiele für reduzible Zustandsräume in graphischer Form

$P_1$ :



$P_2$ :




Zustandsraum  $S = \{A, B, C\}$  kann auf  $C = \{A, B\}$  (rot markiert) reduziert werden, C ist dann irreduzibel.

## Essentielle/finale Zustände

- Zustand  $i$  heißt **essentiell/final**, falls  $\forall_j j \leftrightarrow i$ , also wenn er mit allen anderen Zuständen kommuniziert.

Graphisches Beispiel:



Alle Zustände sind essentiell, da sie miteinander kommunizieren. Eine irreduzible bzw. stark verbundene **MK** besteht also aus essentiellen/finalen Zuständen.

# Der Zerlegungssatz

Der Zustandsraum  $S$  einer Markov-Kette  $\mathbf{X}$  lässt sich zerlegen in

- ① eine Menge  $T$  mit transienten Zuständen
- ② Mengen  $C_k$ , die irreduzibel und geschlossen sind

$$\Rightarrow S = T \cup C_1 \cup C_2 \cup \dots$$

Ferner gilt folgendes Lemma:

Wenn  $S$  endlich ist, dann ist mindestens ein Zustand rekurrent und alle rekurrenten Zustände sind nicht-leer.

## Beispiel

Eine Markov-Kette mit Zustandsraum  $S = \{1, 2, 3, 4, 5, 6\}$  habe die Übergangsmatrix

$$\mathbf{P} = \begin{pmatrix} 0.5 & 0.5 & 0 & 0 & 0 & 0 \\ 0.25 & 0.75 & 0 & 0 & 0 & 0 \\ 0.25 & 0.25 & 0.25 & 0.25 & 0 & 0 \\ 0.25 & 0 & 0.25 & 0.25 & 0 & 0.25 \\ 0 & 0 & 0 & 0 & 0.5 & 0.5 \\ 0 & 0 & 0 & 0 & 0.5 & 0.5 \end{pmatrix}$$

Man bestimme:

- die Periode jedes Zustands
- die Zerlegung des Zustandsraumes
- transiente Zustände
- ergodische Zustände

## 7.3 Die stationäre Verteilung und das Grenzwerttheorem

Eine Wahrscheinlichkeitsverteilung  $\pi$  (Zeilenvektor) mit Einträgen  $(\pi_j : j \in S)$  heißt **stationäre Verteilung** einer Markov-Kette  $\mathbf{X}$  mit Übergangsmatrix  $\mathbf{P}$ , falls gilt:

$$\pi_j = \sum_i \pi_i p_{ij}$$

oder in Matrixnotation:

$$\boldsymbol{\pi} = \boldsymbol{\pi} \cdot \mathbf{P}$$

# Interpretation der stationären Verteilung

Hat die Markov-Kette  $\mathbf{X}$  die Verteilung  $\pi$  zu einem gewissen Zeitpunkt  $n$ , dann auch im nächsten Zeitpunkt  $n + 1$  und sogar in allen nachfolgenden Zeitpunkten  $i = n + 2, n + 3, \dots$

Betrachte z.B.  $i = n + 2$ :

$$\pi \cdot \mathbf{P}^2 = (\pi \mathbf{P}) \mathbf{P} = \pi \mathbf{P} = \pi$$

Oft wählt man für die Anfangsverteilung  $\mu_0$  die stationäre Verteilung, d.h.  $\mu_0 = \pi$ .

Im Folgenden betrachten wir ausschließlich irreduzible Markov-Ketten, d.h. Markov-Ketten mit irreduziblem Zustandsraum  $S$ .

## Satz über die stationäre Verteilung

Eine irreduzible Markov-Ketten hat eine **stationäre Verteilung**  $\pi$  mit  $\pi_i > 0 \forall_i$ .

Dann ist  $\pi$  eindeutig und gegeben durch

$$\pi_i = 1/\mu_i$$

wobei  $\mu_i$  die erwartete Rekurrenzzeit des Zustands  $i$  ist.

Unter diesen Voraussetzungen gilt bei endlichem Zustandsraum:

$$\pi = \mathbf{1}(\mathbf{I} - \mathbf{P} + \mathbf{U})^{-1}$$

wobei  $\mathbf{I}$  die Einheitsmatrix und  $\mathbf{1}$  ein Zeilenvektor mit Einsen ist und  $\mathbf{U}$  nur Elemente gleich eins hat.

## Bestimmung der stationären Verteilung bei $|S| = 2$

Stationäre Verteilung und Übergangsmatrix haben bei Markov-Ketten mit zwei Zuständen folgende allgemeine Formen:

$$\boldsymbol{\pi} = (\pi_1, 1 - \pi_1) \quad \mathbf{P} = \begin{pmatrix} 1 - p_{12} & p_{12} \\ p_{21} & 1 - p_{21} \end{pmatrix}$$

Die erste Spalte der Gleichung  $\boldsymbol{\pi} = \boldsymbol{\pi} \cdot \mathbf{P}$  ist

$$\begin{aligned} \pi_1 &= \pi_1 - \pi_1 \cdot p_{12} + p_{21} - \pi_1 \cdot p_{21} \\ \Rightarrow \pi_1 &= \frac{p_{21}}{p_{12} + p_{21}} \quad \text{und} \quad \pi_2 = \frac{p_{12}}{p_{12} + p_{21}} \end{aligned}$$

Die zweite Spalte ergibt die gleiche Lösung.

## Beispiel

Wie lautet die stationäre Verteilung für die Markov-Kette mit folgender Übergangsmatrix:

$$\mathbf{P} = \begin{pmatrix} 0.9 & 0.1 \\ 0.4 & 0.6 \end{pmatrix}$$

Mit der eben bestimmten Formel erhält man:

$$\boldsymbol{\pi} = (\pi_1, \pi_2) = \left( \frac{0.4}{0.5}, \frac{0.1}{0.5} \right) = (0.8, 0.2)$$

Die erwarteten Rekurrenzzeiten sind demnach  $\mu_1 = 5/4$  für Zustand 1 und  $\mu_2 = 5$  für Zustand 2.

Wie verhält es sich bei

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

# Reversible Markov-Ketten

Sei  $\mathbf{X} = (X_0, \dots, X_N)$  eine reguläre Markov-Kette mit Übergangsmatrix  $\mathbf{P}$  und stationärer Verteilung  $\pi$ , die  $\mathbf{X}$  auch zu jedem Zeitpunkt  $n = 0, \dots, N$  besitze.

Definiere nun  $\mathbf{Y} = (X_N, \dots, X_0)$  mit  $Y_n = X_{N-n}$ .

Dann ist  $\mathbf{Y}$  auch eine Markov-Kette mit Übergangswahrscheinlichkeiten

$$P(Y_{n+1} = j | Y_n = i) = (\pi_j / \pi_i) p_{ji}$$

## Reversible Markov-Ketten II

Man sagt nun  $\mathbf{X}$  ist **reversibel**, falls  $X$  und  $Y$  identische Übergangswahrscheinlichkeiten haben, d.h. falls

$$\pi_i p_{ij} = \pi_j p_{ji}$$

für alle  $i, j \in S$  gilt.

# Beispiele für reversible Markov-Ketten

- 1 Alle irreduziblen Markov-Ketten mit zwei Zuständen sind reversibel (Beweis in Vorlesung).
- 2 Markov-Ketten mit tri-diagonaler Übergangsmatrix  $\mathbf{P}$  sind reversibel, z.B.
  - ▶ der **random walk** auf endlichem Zustandsraum  $S = \{0, 1, \dots, b\}$
  - ▶ der Prozess aus Beispiel 2 (Stichwort: Genhäufigkeit)

# Satz über die stationäre Verteilung

Sei  $\mathbf{X}$  eine irreduzible Markov-Kette mit Übergangsmatrix  $\mathbf{P}$ . Ferner gebe es eine Verteilung  $\pi$  mit  $\pi_i p_{ij} = \pi_j p_{ji}$  für alle  $i, j \in S$ .

Dann ist  $\pi$  die stationäre Verteilung und  $\mathbf{X}$  ist bzgl.  $\pi$  reversibel.

Beweis:

$$\sum_i \pi_i p_{ij} = \sum_i \pi_j p_{ji} = \pi_j \sum_i p_{ji} = \pi_j$$

# Das Grenzwerttheorem

Eine irreduzible und aperiodische Markov-Kette konvergiert gegen ihre stationäre Verteilung  $\pi$

$$p_{ij}(n) \longrightarrow \pi_j = \mu_j^{-1} \quad \text{für } n \rightarrow \infty \text{ und alle } i$$

bzw.

$$\mathbf{P}_n = \mathbf{P}^n \longrightarrow \begin{pmatrix} \cdots & \boldsymbol{\pi} & \cdots \\ \cdots & \boldsymbol{\pi} & \cdots \\ \vdots & \vdots & \vdots \\ \cdots & \boldsymbol{\pi} & \cdots \end{pmatrix}$$

Daher gilt  $\boldsymbol{\mu}^{(0)} \mathbf{P}_n \longrightarrow \boldsymbol{\pi}$  für alle  $\boldsymbol{\mu}^{(0)}$ .

# Ein Gegenbeispiel

Eine Markov-Kette  $\mathbf{X}$  mit Übergangsmatrix

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

hat zwar die stationäre Verteilung  $\boldsymbol{\pi} = (1/3, 1/3, 1/3)$ , konvergiert aber nicht gegen diese, da die Kette periodisch ist.

## 7.4 Inferenz für Markov-Ketten

- Schätzung der Übergangswahrscheinlichkeiten
- Test auf Modellanpassung
- Allgemeinere Markov-Modelle:
  - ▶ Markov-Ketten höherer Ordnung
  - ▶ Hidden-Markov Modelle

# Schätzung der Übergangswahrscheinlichkeiten

Ziel: Schätzung der Übergangswahrscheinlichkeiten basierend auf einer (oder mehrerer) Realisationen einer Markov-Kette  $\mathbf{X}$ .

Es erscheint plausibel, die Übergangswahrscheinlichkeiten  $p_{ij}$  durch die entsprechenden **Übergangshäufigkeiten**

$$\hat{p}_{ij} = \frac{n_{ij}}{n_i}$$

zu schätzen, wobei  $n_{ij}$  die Anzahl der beobachteten Übergänge von  $i$  nach  $j$  ist und  $n_i = \sum_j n_{ij}$ .

Im Folgenden zeigen wir, dass dies auch die ML-Schätzer sind.

# ML-Schätzung der Übergangswahrscheinlichkeiten

Grundlage: Realisation  $X_0 = x_0, X_1 = x_1, \dots, X_N = x_N$  einer Markov-Kette  $\mathbf{X}$ .

Die Likelihood ist somit (vergleiche Folie S. 13)

$$L(\mathbf{P}) = \mu_{x_0}^{(0)} \prod_{t=1}^n p_{x_{t-1}, x_t} = \mu_{x_0}^{(0)} \prod_{i,j} p_{ij}^{n_{ij}}$$

wobei  $n_{ij}$  die Anzahl der beobachteten Übergänge von  $i$  nach  $j$  ist.  
Die Log-Likelihood ist dann

$$l(\mathbf{P}) = \log(\mu_{x_0}^{(0)}) + \sum_{i,j} n_{ij} \log(p_{ij})$$

# ML-Schätzung der Übergangswahrscheinlichkeiten II

Problem: Es sind mehrerer Parameter in  $\theta = \mathbf{P}$  durch Maximierung der Log-Likelihood  $l(\mathbf{P})$  zu schätzen, wobei noch die Restriktion

$$\sum_j p_{ij} = 1$$

für alle  $i$  zu berücksichtigen ist.

⇒ *Lagrangische Multiplikatorenmethode*:

Maximiere

$$l^*(\mathbf{P}) = \log(\mu_{x_0}^{(0)}) + \sum_{i,j} n_{ij} \log(p_{ij}) - \sum_i \lambda_i \left( \sum_j p_{ij} - 1 \right)$$

# ML-Schätzung der Übergangswahrscheinlichkeiten III

Die partiellen Ableitungen nach  $p_{ij}$  sind somit

$$\frac{dl^*(\mathbf{P})}{p_{ij}} = \frac{n_{ij}}{p_{ij}} - \lambda_i$$

Nullsetzen liefert  $n_{ij} = \lambda_i p_{ij}$ . Durch Summation über  $j$  folgt

$$\lambda_i = \sum_j n_{ij} = n_i$$

und schließlich

$$\hat{p}_{ij} = \frac{n_{ij}}{n_i}.$$

## Beispiel: Regen bei den Snoqualmie Wasserfällen

Über eine Zeitreihe von  $N = 13149$  Tagen wurde an den Snoqualmie Wasserfällen registriert, ob es am jeweiligen Tag geregnet hat oder nicht.

### Erstellung eines Markov-Modells:

Der Zustandsraum ist  $S = \{0, 1\}$  mit

$$\left. \begin{array}{l} 0 : \text{Kein Regen} \\ 1 : \text{Regen} \end{array} \right\} \text{ am Tag } t = 1, \dots, N$$

Es ergibt sich  $n_0 = 6229$  (Tage ohne Regen) und  $n_1 = 6920$ .

Übergangsmatrix mit relativen Übergangshäufigkeiten (*ML*-Schätzer):


$$\hat{\mathbf{P}} = \begin{pmatrix} 0.713 & 0.287 \\ 0.258 & 0.742 \end{pmatrix}$$

Frage: Passt sich das Markov-Modell den Daten gut an?


→ Betrachtung der “Verweildauern” (Wartezeiten bis zum nächsten Zustandswechsel)

# Verweildauern bei den Snoqualmie Wasserfällen

Verweildauer im Zustand 0 (kein Regen)



Verweildauer im Zustand 1 (Regen)



Theoretische (schwarz) und empirische (rot) Verweildauern in den beiden Zuständen.

# Markov-Ketten höherer Ordnung

Zum Beispiel Markov-Kette *zweiter* Ordnung:

Die Regenwahrscheinlichkeit hängt nun von den letzten *zwei* Tagen ab.  
Die Übergangswahrscheinlichkeiten sind

$$P(X_n = s | X_{n-1} = x_{n-1}, X_{n-2} = x_{n-2}).$$

Diese Markov-Kette kann auch als Markov-Kette erster Ordnung dargestellt werden, indem man den Zustandsraum zu  $S = \{00, 01, 10, 11\}$  erweitert, wobei der erste Eintrag  $x_{n-2}$  und der zweite Eintrag  $x_{n-1}$  darstellt.

→ In der Übergangsmatrix ergeben sich dann **strukturelle Nullen**.

# Strukturelle Nullen

Im Beispiel ergibt sich:

$$\mathbf{P} = \begin{pmatrix} & \begin{array}{c|cc|cc} & 00 & 01 & 10 & 11 \\ \hline 00 & & & 0 & 0 \\ 01 & 0 & 0 & & \\ 10 & & & 0 & 0 \\ 11 & 0 & 0 & & \end{array} \\ \hline \end{pmatrix}$$

da z.B. auf  $X_{n-2} = 0$  und  $X_{n-1} = 0$  nicht  $X_{n-1} = 1$  und  $X_n = 0$  folgen kann etc.

→ die Anzahl der Spalten kann reduziert werden

# Regen bei den Snoqualmie Wasserfällen

Mit reduzierten Spalten ergibt sich im Beispiel

$$\hat{\mathbf{P}} = \left( \begin{array}{c|cc} & 0 & 1 \\ \hline 00 & 0.749 & 0.251 \\ 01 & 0.277 & 0.723 \\ 10 & 0.624 & 0.376 \\ 11 & 0.252 & 0.748 \end{array} \right)$$

Alternativer Ansatz: Hidden Markov-Modell

## 7.5 Hidden Markov Modelle

- **Mischverteilungsmodell** mit zusätzlichem Zeitreihencharakter
- **Anwendungen** in verschiedenen Bereichen:
  - ▶ Ökonometrie,
  - ▶ Genetik (DNA-Sequenzierung, Stammbaumanalyse),
  - ▶ Spracherkennung, ...

# Das Modell

Latente Parameter  $\mathbf{X} = (X_1, \dots, X_N)$  folgen einer (homogenen) **Markov-Kette** mit diskretem Zustandsraum  $S$ :

- Übergangsmatrix  $\mathbf{P}$  mit  $p_{ij} = P(X_t = j | X_{t-1} = i)$
- Anfangsverteilung  $\boldsymbol{\pi}$  mit  $\pi_i = P(X_0 = i)$   
(oft impliziert durch  $\boldsymbol{\pi} = \boldsymbol{\pi}\mathbf{P}$ )

Die Beobachtungen  $y_t | x_t = s$  sind **bedingt unabhängig** aus einer Verteilung mit Wahrscheinlichkeitsfunktion  $f_s(y_t)$  mit Parametern  $\boldsymbol{\theta}_s$ .

Beispielsweise:

- **diskret** mit Missklassifizierungswahrscheinlichkeiten  $p_s$
- **Poisson** mit Raten  $\lambda_s$

## Beispiel: Ein verrauschtes binäres Signal

Daten:

$$\mathbf{y} = (2 \ 2 \ 2 \ 1 \ 2 \ 2 \ 1 \ 1 \ 1 \ 1 \ 1 \ 2 \ 1 \ 1 \ 1 \ 2 \ 1 \ 2 \ 2 \ 2)$$

$$\begin{array}{l} |S| = 2 \\ N = 20 \end{array} \quad \mathbf{P} = \begin{pmatrix} 0.75 & 0.25 \\ 0.25 & 0.75 \end{pmatrix} \quad \boldsymbol{\pi} = \begin{pmatrix} 0.5 \\ 0.5 \end{pmatrix}$$

$$f(y_t = 1 | x_t = 1) = 0.8 \quad f(y_t = 1 | x_t = 2) = 0.2$$

$$f(y_t = 2 | x_t = 1) = 0.2 \quad f(y_t = 2 | x_t = 2) = 0.8$$

Ziel der statistischen Inferenz: **Restauration** der Sequenz  $\mathbf{X}$

# Inferenz bei festen Hyperparametern

- Hyperparameter:  $\mathbf{P}$ ,  $\boldsymbol{\pi}$ ,  $\boldsymbol{\theta}$  fest
- Ziel: **Schätzung** der latenten Zustände  $\mathbf{x} = (x_1, \dots, x_N)$
- **Posteriori-Verteilung**  $f(\mathbf{x}|\mathbf{y}) = f(\mathbf{x}, \mathbf{y})/f(\mathbf{y})$  mit:

$$f(\mathbf{x}|\mathbf{y}) \propto f(\mathbf{x}, \mathbf{y}) = \underbrace{\pi_{x_1} \prod_{t=2}^N p_{x_{t-1}x_t}}_{f(\mathbf{x})} \cdot \underbrace{\prod_{t=1}^N f_{x_t}(y_t)}_{f(\mathbf{y}|\mathbf{x})}$$

- **Problem:** Es gibt  $S^N$  (!) unterschiedliche Sequenzen  $\mathbf{x}$ .

- **Viterbi-Algorithmus** [Viterbi (1967)]
  - ▶ Rekursiver Algorithmus zur Maximierung von  $f(\mathbf{x}, \mathbf{y})$  bzgl.  $\mathbf{x}$
  - ▶ liefert (einen) MAP-(posteriori Modus)-Schätzer von  $f(\mathbf{x}|\mathbf{y}) \propto f(\mathbf{x}, \mathbf{y})$
  - ▶ Algorithmus ist numerisch effizient:  $O(|S|^2 \cdot N)$
- **Simulated annealing** [Kirkpatrick, Gelatt & Vecchi (1983)]

# Rekonstruktion des verrauschten binären Signals

Das empfangene Signal war

$$\mathbf{y} = (2\ 2\ 2\ 1\ 2\ 2\ 1\ 1\ 1\ 1\ 1\ 2\ 1\ 1\ 1\ 2\ 1\ 2\ 2\ 2)$$

Daraus kann man Schätzer für das zugrundeliegende Signal  $\mathbf{x}$  berechnen:

Schätzer von $\mathbf{x}$	post. Wkeit $P(\mathbf{x} \mathbf{y})$
$\hat{\mathbf{x}}_{MAP_1} = (2\ 2\ 2\ 2\ 2\ 2\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 2\ 2\ 2)$	0.0304
$\hat{\mathbf{x}}_{MAP_2} = (2\ 2\ 2\ 2\ 2\ 2\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 2\ 2\ 2\ 2\ 2)$	0.0304
$\hat{\mathbf{x}}_{MPM} = (2\ 2\ 2\ 2\ 2\ 2\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 2\ 1\ 2\ 2\ 2)$	0.0135
$\mathbf{y} = (2\ 2\ 2\ 1\ 2\ 2\ 1\ 1\ 1\ 1\ 1\ 2\ 1\ 1\ 1\ 2\ 1\ 2\ 2\ 2)$	0.0027

Hierbei bezeichnet  $\hat{\mathbf{x}}_{MPM}$  den marginalen Posteriori Modus, d.h. jedes  $x_i$ ,  $i = 1, \dots, 20$ , in  $\hat{\mathbf{x}}_{MPM}$  hat marginale Posteriori-Wahrscheinlichkeit  $P(x_i|\mathbf{y}) > 0.5$ .

## Inferenz bei unbekannten Hyperparametern

Seien nun bestimmte Hyperparameter  $\theta$  unbekannt, wie beispielsweise die Übergangsmatrix  $\mathbf{P}$  oder die Verteilung  $f(y_i|x_i)$ .

- **Klassische** Likelihood-Ansätze maximieren die (marginale) Likelihood  $L(\theta) = f(\mathbf{y}|\theta)$  bezüglich  $\theta$ , z.B. mit dem Baum-Welch-Algorithmus, der einen Spezialfall des EM-Algorithmus darstellt.

Problem: Berechnung von  $f(\mathbf{y}|\theta) = \sum_{\mathbf{x}} f(\mathbf{x}, \mathbf{y}|\theta)$

- **Bayesianische** Ansätze verwenden zusätzliche priori-Verteilungen  $f(\theta)$  und simulieren aus der posteriori-Verteilung

$$f(\mathbf{x}, \theta|\mathbf{y}) \propto f(\mathbf{x}, \mathbf{y}|\theta) \cdot f(\theta)$$

mit Markov-Ketten Monte Carlo (MCMC) Verfahren.

## Beispiel zur Likelihood-Inferenz

Seien nun die Einträge der Übergangsmatrix  $\mathbf{P}$  unbekannt. Die marginale Likelihood  $L(p_{11}, p_{22})$  der Diagonalelemente  $p_{11}$  und  $p_{22}$  ist in folgender Graphik dargestellt. Die ML-Schätzungen sind  $\hat{p}_{11} = 0.85$  und  $\hat{p}_{22} = 0.78$ .

