

## Kapitel 4: Irreduzible und aperiodische Markov Ketten<sup>1</sup>

Für einige besonders interessante Ergebnisse der Markov Theorie, werden zunächst bestimmte Annahme über Markov Ketten betrachtet. Es ist eine wichtige Aufgabe in der Markov Theorie Bedingungen zu finden, die einerseits stark genug sind, damit man hilfreiche Behauptungen erstellen kann, aber andererseits auch schwach genug für viele gute Beispiele sind. In diesem Kapitel geht es um zwei solcher Annahmen: **Irreduzibilität** und **Aperiodizität**. Diese beiden Bedingungen sind von zentraler Bedeutung in der Markov Theorie und insbesondere spielen sie in der Forschung über stationäre Verteilung eine wichtige Rolle.

Wir beginnen mit Irreduzibilität, was, einfach gesprochen, die Eigenschaft ist, dass alle Stadien der Markov Kette von allen anderen Stadien erreicht werden können. Um dies genauer zu beschreiben, betrachten wir eine Markov Kette  $(X_0, X_1, \dots)$  mit Zustandsraum  $S = \{s_1, \dots, s_k\}$  und Übergangsmatrix  $P$ . Wir sagen, dass der Zustand  $s_i$  mit einem anderen Zustand  $s_j$  **kommuniziert** (geschrieben:  $s_i \rightarrow s_j$ ), wenn die Wahrscheinlichkeit, dass, beginnend bei  $s_i$ , die Kette  $s_j$  erreicht, positiv ist. In anderen Worten:  $s_i$  und  $s_j$  kommunizieren, wenn es ein  $n$  gibt, so dass  $\mathbf{P}(X_{m+n}=s_j \mid X_m = s_i) > 0$  bzw.  $(P_{ij})^{(n)} > 0$ .

Wenn  $s_i \rightarrow s_j$  und  $s_j \leftarrow s_i$ , dann sagt man die Zustände  $s_i$  und  $s_j$  sind **verbunden**, und schreibt:  $s_i \leftrightarrow s_j$ . Dies bringt uns gleich zu der Definition von Irreduzibilität:

Definition 4.1 Eine Markov Kette  $(X_0, X_1, \dots)$  mit Zustandsraum  $S=\{s_1, \dots, s_k\}$  und Übergangsmatrix  $P$  heißt **irreduzibel**, falls für alle  $s_j, s_i \in S$  gilt:  $s_i \leftrightarrow s_j$ . Sonst heißt die Markov Kette **reduzibel**.

Oder anders gesagt: Die Kette ist irreduzibel, falls es für alle  $s_j, s_i \in S$  ein  $n$  gibt, so dass  $(P^n)_{i,j} > 0$ .

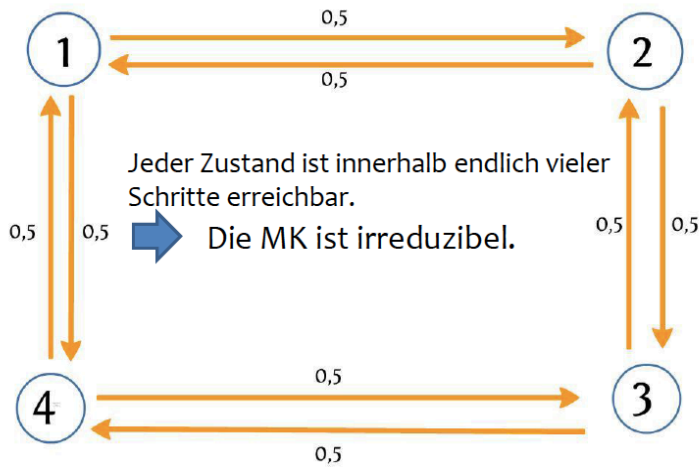
Um zu zeigen, dass eine Markov Kette irreduzibel ist, betrachtet man das Übergangendiagramm und überprüft, ob man von jedem Zustand innerhalb endlich vieler Schritte zu jedem anderen Zustand gelangen kann.

---

<sup>1</sup> Olle Häggström, "Finite Markov Chains and Algorithmic Applications", Cambridge 2002, S. 22-27.

**Beispiele:**

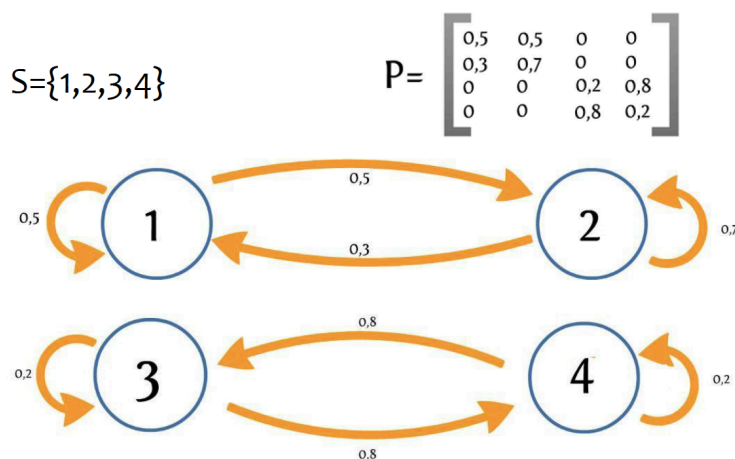
**1. The random walker**



2. Die Markov Kette  $(X_0, X_1, \dots)$  mit Zustandsraum  $S = \{1, 2, 3, 4\}$  und

Übergangsmatrix  $P = \begin{bmatrix} 0.5 & 0.5 & 0 & 0 \\ 0.3 & 0.7 & 0 & 0 \\ 0 & 0 & 0.2 & 0.8 \\ 0 & 0 & 0.8 & 0.2 \end{bmatrix}$  ist zum Beispiel reduzibel, denn

beginnt die Kette mit Zustand 1 oder 2 ist sie eingeschränkt auf Zustand 1 und 2. Dasselbe gilt für Zustand 3 und 4, einmal dort kann sie nicht zu Zustand 1 oder 2 wechseln.



(Betrachtet man die Kette nur in Zustand 1 oder 2, dann verhält sie sich wie eine Markov Kette mit Zustandsraum  $\{1, 2\}$  und Übergangsmatrix  $\begin{bmatrix} 0.5 & 0.5 \\ 0.3 & 0.7 \end{bmatrix}$ . Dies zeigt eine charakteristische Eigenschaft für reduzible Markov Ketten, welches den Begriff „reduzibel“ noch einmal erklärt: Wenn eine Markov Kette reduzibel ist, dann kann

das Langzeitverhalten auf die Analyse von den Langzeitverhalten mehrerer Markov Ketten mit kleineren Zustandsräumen reduziert werden.)

### Das Konzept der Aperiodizität

Für eine endliche oder unendliche Menge positiver ganzer Zahlen  $\{a_1, a_2, \dots\}$ , schreiben wir  $\text{ggT}\{a_1, a_2, \dots\}$  für den größten gemeinsamen Teiler von  $a_1, a_2, \dots$ . Die

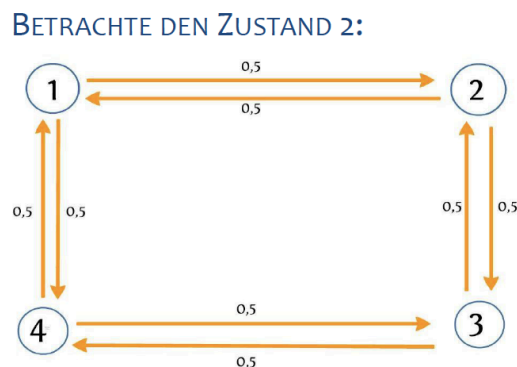
**Periode**  $d(s_i)$  eines Zustandes  $s_i \in S$  ist definiert als  $d(s_i) = \text{ggT}\{n \geq 1: (P^n)_{i,i} > 0\}$ .

In Worten: Die Periode von  $s_i$  ist der größte gemeinsame Teiler von der Menge der möglichen Rückkehrzeiten zum Startpunkt  $X_0 = s_i$ . Wenn  $d(s_i) = 1$ , sagt man, der Zustand  $s_i$  ist **aperiodisch**.

Definition 4.2 Eine Markov Kette heißt **aperiodisch**, falls alle Zustände aperiodisch sind. Ansonsten heißt die Kette **periodisch**.

Anschaulich ist eine Markov Kette periodisch, wenn man trotz der Zufälligkeit des Gesamtsystems exakte Voraussagen darüber treffen kann, in welcher Teilmenge der Zustandsmenge sich das System an einem bestimmten Zeitpunkt befinden wird.

### **Beispiel periodisch Random walker:**




$$d(2) = \text{ggT}\{n \geq 1: (P^n)_{i,i} > 0\}$$

$$= \text{ggT}(2, 4, 6, 8, \dots) = 2$$

Der Random Walker steht zum Zeitpunkt 0 in der Ecke  $v_1$ . Er muss also eine gerade Anzahl an Schritten nehmen um zurück zu  $v_1$  zu kommen. Das heißt  $(P^n)_{i,i} > 0$  nur für  $n = 2, 4, 6, \dots$  daraus folgt:  $\text{ggT}\{n \leq 1: (P^n)_{i,i} > 0\} = \text{ggT}\{2, 4, 6, \dots\} = 2$  und die Kette ist also periodisch.

**Beispiel aperiodisch:**



$$d(1) = \text{ggT} \{n \geq 1: (P^n)_{i,i} > 0\}$$

$$= \text{ggT}(1,3) = 1$$

**Beispiel Gothenburger Wetter:** Man nimmt an, dass es nur zwei verschiedene Zustände des Wetters gibt: Regen und Sonnenschein. In Gothenburg liegt die Wahrscheinlichkeit, dass das Wetter morgen genauso ist wie heute, bei 75%. Dann ist das Wetter eine Markov Kette mit Zustandsraum  $S = \{s_1, s_2\}$  (mit  $s_1 = \text{„Regen“}$  und  $s_2 = \text{„Sonnenschein“}$ ) und der Übergangsmatrix  $P = \begin{bmatrix} 0.75 & 0.25 \\ 0.25 & 0.75 \end{bmatrix}$ .

Es ist einfach zu erkennen, dass, ohne Einschränkungen ob es regnet oder die Sonne scheint, die Wahrscheinlichkeit, dass wir das gleiche Wetter  $n$  Tage später haben, für alle  $n$  echt positiv ist. Also:  $(P^n)_{i,i} > 0$  für alle  $n$  und alle Zustände  $s_i$ . Dies beinhaltet offensichtlich, dass die Markov Kette irreduzibel ( $s_i \leftrightarrow s_j$ ) und aperiodisch ( $\text{ggT} = 1$ ) ist.

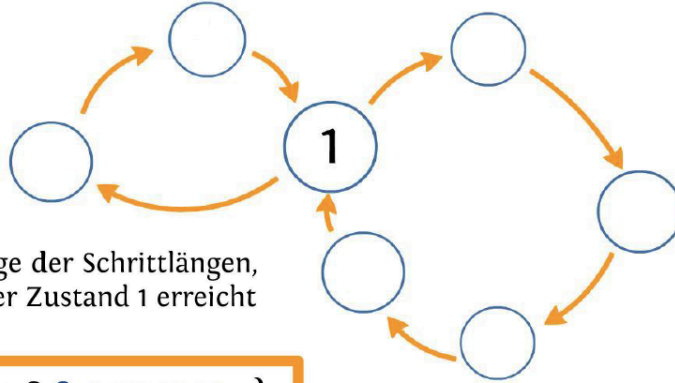
Theorem 4.1: Sei  $(X_0, X_1, \dots)$  eine aperiodische Markov Kette mit dem Zustandsraum  $S = \{s_1, \dots, s_k\}$  und Übergangsmatrix  $P$ .

Dann existiert ein  $N < \infty$ , so dass  $(P^n)_{i,i} > 0$  für alle  $s_i \in S$  und alle  $n \geq N$ .

In Worten: Für eine aperiodische Markov Kette existiert eine Schrittzahl  $N$ , so dass für alle darauffolgenden Schritte  $n \geq N$  die Wahrscheinlichkeit, dass der Zustand  $s_i$  in den Ausgangszustand  $s_i$  zurückkehrt für alle  $s_i \in S$  positiv ist.

Die Markovkette ist offensichtlich aperiodisch, denn:

$$d(1) = \text{ggT}\{3,5\} = 1$$



Sei A die Menge der Schrittlängen, nach denen der Zustand 1 erreicht werden kann.

$$A = \{3, 5, 6, 8, 9, 10, 11, 12, \dots\}$$

→  $N=8$       oder 10, 37, 294, ...



Um das Theorem zu beweisen, benötigt man folgendes Lemma aus der Zahlentheorie:

Lemma 4.1: Sei  $A = \{a_1, a_2, \dots\}$  eine Menge positiver ganzer Zahlen für die gilt:

- (i) A ist teilerfremd, also  $\text{ggT}\{a_1, a_2, \dots\} = 1$
- (ii) A ist abgeschlossen bezüglich der Addition.

Dann existiert ein positives ganzzahliges  $N < \infty$ , mit  $n \in A$  für alle  $n \geq N$ .

(Beweis siehe Brémaud)

## Beispiel

Sei  $A = \{4, 7\}$

Dann folgt aus (ii), dass auch

**8, 11, 12, 14, 15, 16, 18, 19, 20, 21, 22, ...**

und alle darauf folgenden Zahlen Elemente von A sind.



Beweis von Theorem 4.1: Für  $s_i \in S$  sei  $A_i = \{n \geq 1: (P^n)_{i,i} > 0\}$ , also ist  $A_i$  die Menge der möglichen Rückkehrzeitpunkte zu  $s_i$ , wenn die Markov Kette bei  $s_i$  startet. Wir haben angenommen, dass die Markov Kette aperiodisch ist, dann ist auch der Zustand  $s_i$  aperiodisch und  $A_i$  ist teilerfremd (erste Bedingung von Lemma 4.1 erfüllt  $\checkmark$ ). Des Weiteren ist  $A_i$  abgeschlossen bezüglich der Addition, denn:

Betrachte  $a, a' \in A_i$  (also 2 Schrittmöglichkeiten vom Zustand  $s_i$  zum Zustand  $s_i$  zurückzukehren), dann gilt  $P(X_a = s_i | X_0 = s_i) > 0$  und  $P(X_{a+a'} = s_i | X_a = s_i) > 0$ .

Wir wollen zeigen, dass  $P(X_{a+a'} = s_i | X_0 = s_i) > 0$ .

Es gilt, dass:

$$\begin{aligned} P(X_{a+a'} = s_i | X_0 = s_i) &\geq P(X_a = s_i, X_{a+a'} = s_i | X_0 = s_i) \\ &= P(X_a = s_i | X_0 = s_i) P(X_{a+a'} = s_i | X_a = s_i) \\ &> 0 \end{aligned}$$

Die Summe aller  $a, a' \in A_i$  ist also auch Element der Menge  $A_i$ , also  $a+a' \in A_i$  und somit ist  $A_i$  abgeschlossen bezüglich der Addition (zweite Bedingung von Lemma 4.1 erfüllt  $\checkmark$ ).


$A_i$  erfüllt also die beiden Eigenschaften des Lemma 4.1, dass heißt es existiert eine ganze Zahl  $N_i < \infty$ , so dass  $(P^n)_{i,i} > 0$  mit  $n \in A_i$  für alle  $n \geq N_i$ .

Theorem 4.1 folgt, indem man  $N = \max \{N_1, \dots, N_k\}$  wählt. *q. e. d.*

Wenn man Aperiodizität und Irreduzibilität miteinander kombiniert, erhält man folgendes wichtiges Korollar:

Korollar 4.1: Sei  $(X_0, X_1, \dots)$  eine irreduzible und aperiodische Markov Kette mit Zustandsraum  $S = \{s_1, \dots, s_k\}$  und Übergangsmatrix  $P$ . Dann existiert ein  $M < \infty$ , so dass gilt  $(P^n)_{i,j} > 0$  für alle  $i, j \in \{1, \dots, k\}$  und alle  $n \geq M$ .

Sei  $(X_0, X_1, \dots)$  eine irreduzible, aperiodische MK mit Zustandsraum  $S = \{1, 2, 3, 4, 5\}$  und der Übergangsmatrix  $P$ .




In Worten: Es existiert eine Schrittzahl  $M$ , so dass für alle darauffolgenden Schritte  $n \geq M$  die Wahrscheinlichkeit, dass der Zustand  $s_i$  zum Zustand  $s_j$  geht, positiv ist.

Beweis Korollar 4.1: Wir wissen aus Theorem 4.1: Es existiert ein  $N < \infty$ , so dass  $(P^n)_{i,i} > 0$  für alle  $s_i \in S$  und alle  $n \geq N$ . Und aus der Irreduzibilität folgt: Es existiert ein  $n_{i,j}$ , so dass  $(P^{n_{i,j}})_{i,j} > 0$ .

Wir suchen:  $M_{i,j}$ , so dass für alle  $m \geq M_{i,j}$  gilt:  $\mathbf{P}(X_m = s_j \mid X_0 = s_i) > 0$

Dafür definieren wir  $M_{i,j} = N + n_{i,j}$

$$M_{ij} = N + n_{ij}$$



Für alle  $m \geq M_{i,j}$  haben wir:

$$\begin{aligned} \mathbf{P}(X_m = s_j \mid X_0 = s_i) &\geq \mathbf{P}(X_{m-n_{i,j}} = s_i, X_m = s_j \mid X_0 = s_i) \\ &= \mathbf{P}(X_{m-n_{i,j}} = s_i \mid X_0 = s_i) \mathbf{P}(X_m = s_j \mid X_{m-n_{i,j}} = s_i) \quad \text{*folgt} \\ &\quad \text{durch Bedingung} \\ &\quad \text{der Markov-Kette} \end{aligned}$$

$\mathbf{P}(X_{m-n_{i,j}} = s_i \mid X_0 = s_i) > 0$ , da  $m-n_{i,j} \geq N$  (Theorem 4.1) und

$\mathbf{P}(X_m = s_j \mid X_{m-n_{i,j}} = s_i) > 0$ , nach Definition von  $n_{i,j}$ .

$\Rightarrow \mathbf{P}(X_m = s_j \mid X_0 = s_i) > 0$  für alle  $m \geq M_{i,j}$ .

Das Korollar folgt, indem man  $M = \max \{M_{1,1}, M_{1,2}, \dots, M_{1,k}, M_{2,1}, \dots, M_{k,k}\}$  wählt.

*q. e. d.*

## Kapitel 5: Stationäre Verteilung<sup>2</sup>

In diesem Kapitel geht es um das Langzeitverhalten von Markov Ketten. Was kann man über eine Markov Kette sagen, die sehr lange läuft? Gibt es interessante Limes Theoreme?

Wenn man irgendeine nicht triviale Markov Kette  $(X_0, X_1, \dots)$  betrachtet, wird der Wert von  $X_n$ , selbst mit  $n \rightarrow \infty$ , im Allgemeinen nicht gegen einen bestimmten Wert konvergieren. Wir hoffen jedoch, dass die Verteilung von  $X_n$  sich bezüglich eines Grenzwertes annähert. Dies ist in der Tat der Fall, falls die Markov Kette irreduzibel und aperiodisch ist.

Für die Verteilung der Wahrscheinlichkeiten von  $X_n$  lassen sich hingegen Aussagen über den Grenzwerte machen:

$\mu = (\mu_1, \dots, \mu_k)$  heißt **Wahrscheinlichkeitsverteilung**

$$\Leftrightarrow \mu_i \geq 0 \text{ für } i = 1, \dots, k \text{ und } \sum_{i=1}^k \mu_i = 1$$

Die Wahrscheinlichkeitsverteilung gibt an, wie sich die Wahrscheinlichkeiten auf die möglichen Zufallsergebnisse (Werte der Zufallsvariablen) verteilen.

Definition 5.1: Sei  $(X_0, X_1, \dots)$  eine Markov Kette mit dem Zustandsraum  $S = \{s_1, \dots, s_k\}$  und Übergangsmatrix  $P$ . Ein Vektor  $\pi = (\pi_1, \dots, \pi_k)$  heißt **stationäre Verteilung** der Markov Kette, wenn gilt:

$$(i) \pi_i \geq 0 \text{ für alle } i = 1, \dots, k \text{ und } \sum_{i=1}^k \pi_i = 1$$

$$(ii) \pi P = \pi, \text{ also } \sum_{i=1}^k \pi_i P_{i,j} = \pi_j \text{ für } j = 1, \dots, k$$

Eigenschaft (i) bedeutet, dass  $\pi$  die mögliche Verteilung über  $\{s_1, \dots, s_k\}$  beschreibt. (ii) besagt, dass wenn die Anfangsverteilung  $\mu^{(0)}$  gleich  $\pi$  ist, dann entspricht die Verteilung  $\mu^{(1)}$  zum Zeitpunkt 1 der Kette:  $\mu^{(1)} = \mu^{(0)}P = \pi P = \pi$ , und bei Wiederholung sehen wir, dass  $\mu^{(n)} = \pi$  für jedes  $n$ .

---

<sup>2</sup> Olle Häggström, "Finite Markov Chains and Algorithmic Applications", Cambridge 2002, S. 28-33.



**Beispiel Wetter in Los Angeles:** Man nimmt an, dass es nur zwei verschiedene Zustände des Wetters gibt: Regen und Sonnenschein. Dann ist das Wetter eine Markov Kette mit Zustandsraum  $S = \{s_1, s_2\}$  (mit  $s_1 = \text{„Regen“}$  und  $s_2 = \text{„Sonnenschein“}$ ) und der Übergangsmatrix  $P = \begin{pmatrix} 0.5 & 0.5 \\ 0.1 & 0.9 \end{pmatrix}$ .

Wenn wir  $\mu^{(0)} = \left(\frac{1}{6}, \frac{5}{6}\right)$  als Startposition wählen folgt  $\mu^{(0)} = \mu^n$  für alle  $n$  und  $\mu^{(0)}$  heißt stationäre Verteilung der Markov Kette:

$$\begin{pmatrix} \frac{1}{6} & \frac{5}{6} \end{pmatrix} \times \begin{pmatrix} 0.5 & 0.5 \\ 0.1 & 0.9 \end{pmatrix} = \begin{pmatrix} \frac{1}{12} + \frac{1}{12} & \frac{1}{12} + \frac{9}{12} \end{pmatrix} = \begin{pmatrix} \frac{1}{6} & \frac{5}{6} \end{pmatrix}$$

Theorem 5.1 (Existenz von stationären Verteilungen):

Für jede irreduzible, aperiodische Markov Kette existiert mindestens eine stationäre Verteilung.

Um dieses Theorem zu beweisen müssen wir zunächst ein Lemma beweisen, dass sich mit der Treffzeit von Markov Ketten beschäftigt. Hierfür definieren wir zunächst einmal Treffzeit:

$T_{i,j} = \min \{n \geq 1 \mid X_n = s_j\}$  heißt **Treffzeit**.

Die Treffzeit, ist also die Zeit, die nach dem Start in  $s_i$  vergeht bis das erste Mal  $s_j$  besucht wird, wobei  $T_{i,j} = \infty$  falls  $s_j$  niemals besucht wird.

Des Weiteren definieren wir den Erwartungswert:

$\tau_{i,j} = \mathbf{E}(T_{i,j})$  ist der **Erwartungswert** von  $T_{i,j}$ .

Er gibt die erwartete Zeit an, die es braucht mit Startwert  $s_i$  zu Zustand  $s_j$  zu kommen. Für den Fall, dass  $i = j$ , wird  $\tau_{i,j}$  die **mean return time** für Zustand  $s_i$  genannt.

Lemma 5.1: Sei  $(X_0, X_1, \dots)$  eine irreduzible aperiodische Markov Kette mit dem Zustandsraum  $S = \{s_1, \dots, s_k\}$  und Übergangsmatrix  $P$ . Dann gilt für alle  $s_i, s_j \in S$ , dass, wenn die Markov Kette in  $s_i$  startet:

- (i)  $\mathbf{P}(T_{i,j} < \infty) = 1$ , d.h.  $T_{i,j}$  ist endlich
- (ii)  $\mathbf{E}(T_{i,j}) < \infty$ , d.h. der Erwartungswert von  $T_{i,j}$  ist ebenfalls endlich

Beweis Lemma 5.1: Laut Korollar 4.1 existiert für jede aperiodische irreduzible Markov Kette ein  $M > 0$ , sodass  $(P^M)_{i,j} > 0$  für alle  $i, j \in \{1, \dots, k\}$ . Wir setzen

$\alpha = \min\{(P^M)_{i,j} \mid i, j \in \{1, \dots, k\}\}$ , wobei  $\alpha > 0$  die minimalen Einträge der Matrix  $P^M$  angibt.

Setze zwei Zustände  $s_i$  und  $s_j$  fest und starte die Markov Kette in  $s_i$ .

Es folgt:

$$P(T_{i,j} > M) \leq P(X_M \neq s_j) = 1 - \underbrace{P(X_M = s_j)}_{=(P^M)_{i,j}} = 1 - (P^M)_{i,j} \leq 1 - \alpha$$

da  $\{T_{i,j} > M\} \subset \{X_M \neq s_j\}$

Weiter muss betrachtet werden, was zum Zeitpunkt  $2M$  passiert:

$$\begin{aligned} P(T_{i,j} > 2M) &= P(T_{i,j} > M)P(T_{i,j} > 2M \mid T_{i,j} > M) \\ &\leq P(T_{i,j} > M)P(X_{2M} \neq s_j \mid T_{i,j} > M) \\ &\leq (1 - \alpha) (1 - \alpha) \\ &\leq (1 - \alpha)^2 \end{aligned}$$

Wir wiederholen dieses Problem für beliebiges  $l$ :

$$\begin{aligned} P(T_{i,j} > lM) &= P(T_{i,j} > M) P(T_{i,j} > 2M \mid T_{i,j} > M) \times \dots \times P(T_{i,j} > lM \mid T_{i,j} > (l-1)M) \\ &\leq (1 - \alpha)^l \end{aligned}$$

Mit  $l \rightarrow \infty$  läuft  $(1 - \alpha)^l$  gegen 0.

Dies bedeutet  $P(T_{i,j} = \infty) = 0$  und deshalb ist auch  $P(T_{i,j} < \infty) = 1 - P(T_{i,j} = \infty) = 1 - 0 = 1$ , womit (i) bewiesen wäre.

Um (ii) zu beweisen, wird die Definition des Erwartungswertes verwendet:

$$E[X] = \sum_{k=1}^{\infty} P(X \geq k)$$

$$\begin{aligned}
\mathbb{E}[T_{i,j}] &= \sum_{n=1}^{\infty} \mathbf{P}(T_{i,j} \geq n) = \sum_{n=0}^{\infty} \mathbf{P}(T_{i,j} > n) \\
&= \sum_{l=0}^{\infty} \sum_{n=IM}^{(l+1)M-1} \mathbf{P}(T_{i,j} > n) \\
&\leq \sum_{l=0}^{\infty} \sum_{n=IM}^{(l+1)M-1} \mathbf{P}(T_{i,j} > IM) = M \sum_{l=0}^{\infty} \mathbf{P}(T_{i,j} > IM) \\
&\leq M \sum_{l=0}^{\infty} (1-\alpha)^l && \text{Geometrische Reihe} \\
&= M \frac{1}{1-(1-\alpha)} && \text{Sei } q \in \mathbb{R} \text{ mit } |q| < 1 \text{ und } s \text{ eine geometrische Reihe} \quad s_n = \sum_k^n q^k. \\
&= \frac{M}{\alpha} < \infty && \text{Dann folgt für den Wert von } s \\
&&& \lim_{n \rightarrow \infty} s_n = \frac{1}{1-q}
\end{aligned}$$

*q. e. d.*

Beweis Theorem 5.1: Gegeben sei eine Markov Kette  $(X_0, X_1, \dots)$  mit dem Zustandsraum  $S = \{s_1, \dots, s_k\}$  und Übergangsmatrix  $P$ . Wir starten die Kette in  $s_1$  und

definieren:  $\rho_i = \sum_{n=0}^{\infty} P(X_n = s_i, T_{1,1} > n)$  für  $i = 1, \dots, k$

$\rho_i$  ist dann also die erwartete Anzahl an Besuchen des Zustandes  $i$  bis zum Zeitpunkt  $T_{1,1} - 1$ . Da der Erwartungswert von  $\mathbf{E}[T_{1,1}] = \tau_{1,1}$  endlich ist, ist  $\rho_i < \tau_{1,1}$  ebenfalls endlich. Unser Kandidat für unsere stationäre Verteilung ist:

$$\pi = (\pi_1, \dots, \pi_k) = \left( \frac{\rho_1}{\tau_{1,1}}, \frac{\rho_2}{\tau_{1,1}}, \dots, \frac{\rho_k}{\tau_{1,1}} \right).$$

Zunächst müssen wir zeigen, dass die Wahl von  $\pi$  die Bedingungen (i) und (ii) von Definition 5.1 erfüllen:

Zuerst müssen wir beweisen, dass die Relation  $\sum_{i=1}^k \pi_i P_{i,j} = \pi_j$  in Bedingung (ii) für  $j \neq 1$

gilt (der Fall  $j = 1$  wird separat behandelt):

Zur Erinnerung noch mal die zu erfüllenden Bedingungen:

- (i)  $\pi_i \geq 0$  für alle  $i = 1, \dots, k$  und  $\sum_{i=1}^k \pi_i = 1$
- (ii)  $\pi P = \pi$ , also  $\sum_{i=1}^k \pi_i P_{i,j} = \pi_j$  für  $j = 1, \dots, k$

Da wir im Zustand  $s_1$  starten und  $j \neq 1$  ist, ist  $P(X_0 = s_j) = 0$ :

$$\begin{aligned}
\pi_j &= \frac{\rho_j}{\tau_{1,1}} = \frac{1}{\tau_{1,1}} \sum_{n=1}^{\infty} \mathbf{P}(X_n = s_j, T_{1,1} > n) \\
&= \frac{1}{\tau_{1,1}} \sum_{n=1}^{\infty} \mathbf{P}(X_n = s_j, T_{1,1} > n-1) \\
&= \frac{1}{\tau_{1,1}} \sum_{n=1}^{\infty} \sum_{i=1}^k \mathbf{P}(X_{n-1} = s_i, X_n = s_j, T_{1,1} > n-1) \\
&= \frac{1}{\tau_{1,1}} \sum_{n=1}^{\infty} \sum_{i=1}^k \mathbf{P}(X_n = s_j \mid X_{n-1} = s_i, T_{1,1} > n-1) \mathbf{P}(X_{n-1} = s_i, T_{1,1} > n-1) \\
&= \frac{1}{\tau_{1,1}} \sum_{n=1}^{\infty} \sum_{i=1}^k \mathbf{P}(X_n = s_j \mid X_{n-1} = s_i) \mathbf{P}(X_{n-1} = s_i, T_{1,1} > n-1) \\
&\quad \xrightarrow{\qquad \qquad \qquad} = P_{i,j} \\
&= \frac{1}{\tau_{1,1}} \sum_{n=1}^{\infty} \sum_{i=1}^k P_{i,j} \mathbf{P}(X_{n-1} = s_i, T_{1,1} > n-1) \\
&= \frac{1}{\tau_{1,1}} \sum_{i=1}^k P_{i,j} \sum_{n=1}^{\infty} \mathbf{P}(X_{n-1} = s_i, T_{1,1} > n-1) \\
&= \frac{1}{\tau_{1,1}} \sum_{i=1}^k P_{i,j} \sum_{m=0}^{\infty} \mathbf{P}(X_m = s_i, T_{1,1} > m) \\
&= \frac{1}{\tau_{1,1}} \sum_{i=1}^k P_{i,j} \rho_i = \frac{\sum_{i=1}^k P_{i,j} \rho_i}{\tau_{1,1}} = \sum_{i=1}^k \pi_i P_{i,j}
\end{aligned}$$

$$\begin{aligned}
&P(X_n = s_j, T_{1,1} > n-1) \\
&= P(X_n = s_j, T_{1,1} > n) + P(X_n = s_j, T_{1,1} = n) \\
&\quad \xrightarrow{\qquad \qquad \qquad} = \emptyset, \text{ da } j \neq 1
\end{aligned}$$

Als nächstes zeigen wir Bedingung (ii) für den Fall, dass  $j = 1$  ist. Es gilt  $\rho_1 = 1$ , da

$$\left. \begin{array}{l} \text{für } n = 0: P(X_0 = s_1, T_{1,1} > 0) = 1 \\ \text{für } n > 0: P(X_n = s_1, T_{1,1} > n) = P(\emptyset) = 0 \end{array} \right\} \rho_1 = \sum_{n=0}^{\infty} P(X_n = s_1, T_{1,1} > n) = 1$$

$$\begin{aligned}
\rho_1 = 1 &= \mathbf{P}(T_{1,1} < \infty) = \sum_{n=1}^{\infty} \mathbf{P}(T_{1,1} = n) \\
&= \sum_{n=1}^{\infty} \sum_{i=1}^k \mathbf{P}(X_{n-1} = s_i, T_{1,1} = n) \\
&= \sum_{n=1}^{\infty} \sum_{i=1}^k \mathbf{P}(X_{n-1} = s_i, X_n = s_1, T_{1,1} > n-1) \\
&= \sum_{n=1}^{\infty} \sum_{i=1}^k \mathbf{P}(X_n = s_1 | X_{n-1} = s_i) \mathbf{P}(X_{n-1} = s_i, T_{1,1} > n-1) \\
&= \sum_{n=1}^{\infty} \sum_{i=1}^k P_{i,1} \mathbf{P}(X_{n-1} = s_i, T_{1,1} > n-1) \\
&= \sum_{i=1}^k P_{i,1} \sum_{n=1}^{\infty} \mathbf{P}(X_{n-1} = s_i, T_{1,1} > n-1) \\
&= \sum_{i=1}^k P_{i,1} \sum_{m=0}^{\infty} \mathbf{P}(X_m = s_i, T_{1,1} > m) \\
&\qquad\qquad\qquad \longleftarrow = \rho_i \\
&= \sum_{i=1}^k \rho_i P_{i,1}
\end{aligned}$$

Daraus folgt :

$$\pi_1 = \frac{\rho_1}{\tau_{1,1}} = \sum_{i=1}^k \frac{P_{i,1} \rho_i}{\tau_{1,1}} = \sum_{i=1}^k P_{i,1} \pi_i$$

Also ist auch Bedingung (ii) für  $j = 1$  erfüllt. Es bleibt also noch zu zeigen, dass auch Bedingung (i) gilt. Das  $\pi_i \geq 0$  für  $i = 1, \dots, k$  ist offensichtlich.

Um zu sehen, dass auch  $\sum_{i=1}^k \pi_i = 1$  betrachte folgendes:

$$\begin{aligned}
\tau_{1,1} = \mathbf{E}[T_{1,1}] &= \sum_{n=0}^{\infty} \mathbf{P}(T_{1,1} > n) \\
&= \sum_{n=0}^{\infty} \sum_{i=1}^k \mathbf{P}(X_n = s_i, T_{1,1} > n) \\
&= \sum_{i=1}^k \sum_{n=0}^{\infty} \mathbf{P}(X_n = s_i, T_{1,1} > n) \\
&= \sum_{i=1}^k \rho_i
\end{aligned}
\qquad \Rightarrow \qquad
\sum_{i=1}^k \pi_i = \frac{1}{\tau_{1,1}} \sum_{i=1}^k \rho_i = 1$$

Damit ist auch Bedingung (i) gezeigt.

*q. e. d*