

# Q5. Markov-Prozesse in kontinuierlicher Zeit

## Gliederung

1. Zeitkontinuierliche Markov-Prozesse
2. Vom Modell zum Markov-Prozess
3. Stationäre Analyse
4. Transiente Analyse
5. Stationäre Analyse von Modellen mit unendlichem Zustandsraum

## **Literatur (primär)**

- C. G. Cassandras, S. Lafortune

Introduction to Discrete Event Systems. Springer 2008

Kap. 7.3, 7.4

- W. J. Stewart

Numerical Solution of Markov Chains. Princeton University Press

1994, Kap. 1, 5

- P. Buchholz et al

Quantitative Systemanalyse mit Markovschen Ketten

Teubner 1994, Kap. 2, 4, 5, 6, 8

## Ziele:

- Zeitkontinuierliche Markov-Prozessen definieren können
- Modellierungsmächtigkeit zeitkontinuierlicher Markov-Prozesse kennen lernen
- Übergang vom Modell zur Markov-Prozesse kennen lernen
- Systeme mit Hilfe von Markov-Prozessen bewerten können
- Algorithmen zur Analyse von zeitkontinuierlichen Markov-Prozessen kennen lernen
- Das M/M/1-System einordnen und handhaben können
- Ideen zur Analyse von strukturierten unendlichen Systemen kennen lernen

## Q5.1 Zeitkontinuierliche Markov-Prozesse

Wir betrachten Zeit  $T = \mathbb{R}_+$  und

endliche/abzählbare Zustandsräume (bei Bedarf  $X \subseteq \mathbb{N}$ )

Schreibweise  $X(t)$  Zustand zum Zeitpunkt  $t \in \mathbb{R}_+$

Für einen zeitkontinuierlichen Markov-Prozess gilt

$$P[X(t_{k+1})=x_{k+1} | X(t_k)=x_k, \dots, X(t_0)=x_0] = P[X(t_{k+1})=x_{k+1} | X(t_k)=x_k]$$

Für  $t_{k+1} \geq t_k \geq \dots \geq t_0$

d.h. Zukunft hängt nur vom aktuellen Zustand ab!

Beide Markov Bedingungen sind erfüllt:

M1: in der Vergangenheit eingenommene Zustände sind irrelevant

M2: Verweilzeit im aktuellen Zustand ist irrelevant

M2 bedeutet, dass die Verteilung der Restverweilzeit im Zustand unabhängig von der bisherigen Verweilzeit ist (Gedächtnislosigkeit!)

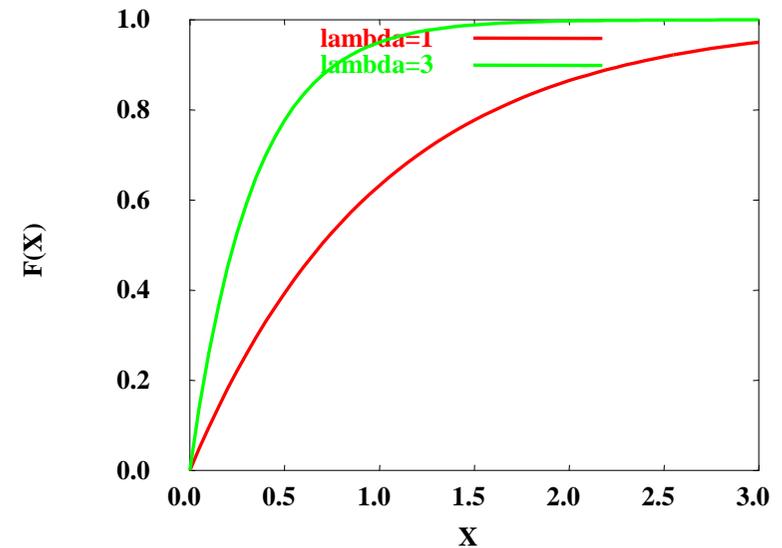
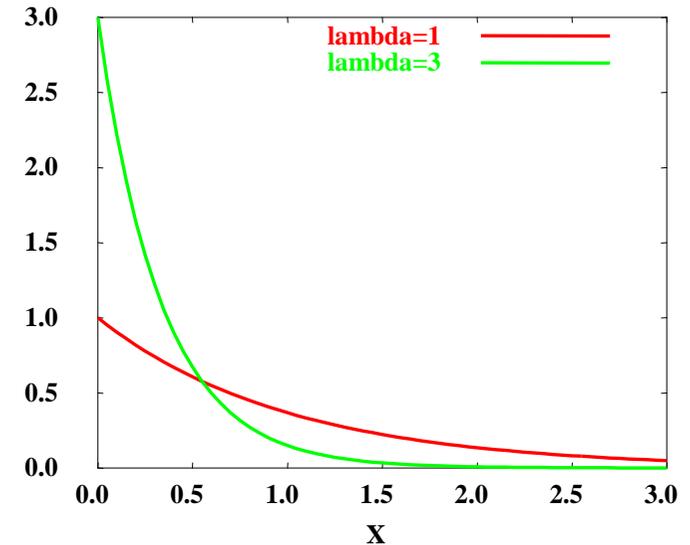
## Einschub:

Exponentialverteilung (Parameter  $\lambda > 0$ )

$$f(x) = \begin{cases} \lambda \cdot e^{-\lambda x} & \text{falls } x \geq 0 \\ 0 & \text{sonst} \end{cases}$$

$$F(x) = \begin{cases} 1 - e^{-\lambda x} & \text{falls } x \geq 0 \\ 0 & \text{sonst} \end{cases}$$

- $E(X) = 1/\lambda$
  - $\sigma^2(X) = 1/\lambda^2$
- $\Rightarrow \text{VK}(X) = 1$



Gedächtnislosigkeitseigenschaft der Exponentialverteilung:

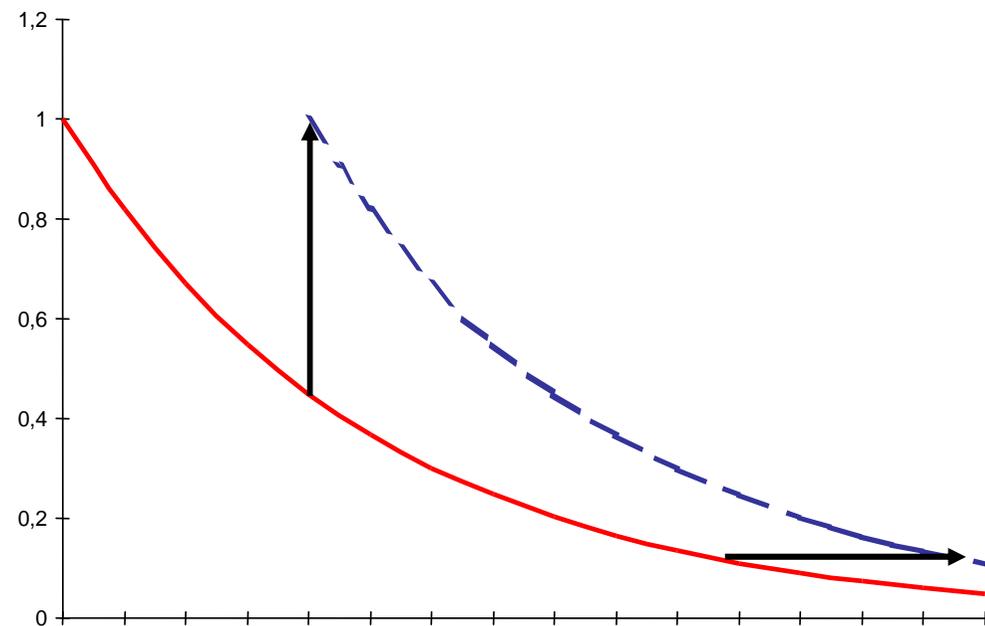
Falls eine ZV  $X$  exponentialverteilt ist, so gilt

$$P[X > t + s \mid X > t] = P[X > s], \text{ da}$$

$$P[X > t + s \mid X > t] = e^{-\lambda(s+t)} / e^{-\lambda t} = e^{-\lambda s} = P[X > s]$$

Dies hat zur Folge, dass die Restzeit einer Exponentialverteilung immer exponentialverteilt mit einer konstanten Rate ist

Die Exponentialverteilung ist die einzige gedächtnislose kontinuierliche Verteilung



Weitere Eigenschaften der Exponentialverteilung:

➤ Additivität: Das Minimum zweier Exponential-Verteilungen mit Raten  $\lambda$  und  $\mu$  ist exponentiell-verteilt mit Rate  $(\lambda + \mu)$

(Offensichtlich kann dies auf eine beliebige Anzahl von Exponential-Verteilungen erweitert werden)

➤ Ausdünnung: Wenn Ereignisse mit exponentiell verteilten Eintrittszeiten mit Rate  $\lambda$  durch eine Zufallsentscheidung nur mit Wahrscheinlichkeit  $p$  akzeptiert werden, so ist die Zeit zwischen zwei akzeptierten Ereignissen exponentiell verteilt mit Rate  $p\lambda$

➤ Falls Ereignisse mit einer exponentialverteilten Generierungszeit mit Rate  $\lambda$  erzeugt werden, so entspricht die Anzahl Ereignisse, die in einem Intervall  $[0,t]$  erzeugt werden, einem Poisson-Prozess mit Rate  $\lambda t$ .

D.h.  $P[k \text{ Ereignisse in einem Intervall der Länge } t] = e^{-\lambda t} (\lambda t)^k / k!$

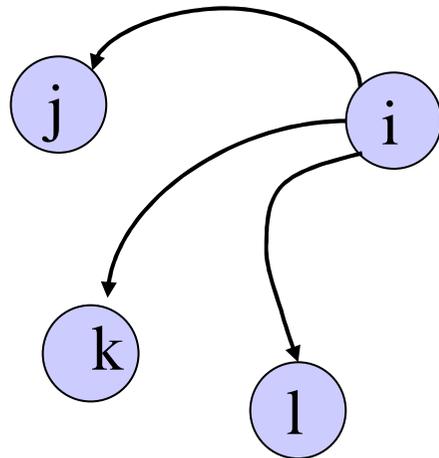
Zurück zu zeitkontinuierlichen Markov-Prozessen:

$$p_{ij}(s,t) = P[X(t) = j \mid X(s) = i]$$

Wir beschränken uns auf homogene Markov-Prozesse, d.h.:

$$p_{ij}(\tau) = P[X(s+\tau) = j \mid X(s) = i] \text{ für alle } s \geq 0$$

Offensichtlich muss  $\sum_j p_{ij}(\tau) = 1$  für alle  $\tau$  gelten



Verhalten ausgehen von  $X_t = i$ :

➤ Im Gegensatz zum zeitdiskreten Fall ist die Anzahl der Transitionen im Intervall  $[t, t+\Delta]$  nicht a priori beschränkt

➤ aber  $\lim_{\Delta \rightarrow 0} p_{ij}(\Delta) = 0$  für  $i \neq j$ , falls die Verweilzeit in einem Zustand durch eine Exponentialverteilung mit endlicher Rate beschrieben ist

$\Rightarrow \lim_{\Delta \rightarrow 0} p_{ii}(\Delta) = 1$  (Summe der Wahrscheinlichkeiten)

Ziel: Untersuchung einzelner Transitionen

$o(\Delta)$  definiert Funktion für die gilt  $\lim_{\Delta \rightarrow 0} (o(\Delta)/\Delta) = 0$

Transitionsrate ist definiert als  $q_{ij} = \lim_{\Delta \rightarrow \infty} \frac{p_{ij}(\Delta)}{\Delta}$  für  $i \neq j$

Damit gilt auch  $p_{ij}(\Delta) = q_{ij}\Delta + o(\Delta)$

Da die Summe der Wahrscheinlichkeiten für jedes  $\Delta$  1 ergeben muss, gilt

$$1 - p_{ii}(\Delta) = \sum_{i \neq j} p_{ij}(\Delta) = \sum_{i \neq j} q_{ij}\Delta + o(\Delta)$$

Bestimmung von  $q_{ii}$ :

$$q_{ii} = \lim_{\Delta \rightarrow 0} \frac{p_{ii}(\Delta) - 1}{\Delta} = \lim_{\Delta \rightarrow 0} \frac{-\sum_{j \neq i} q_{ij}\Delta + o(\Delta)}{\Delta} \Rightarrow q_{ii} = -\sum_{j \neq i} q_{ij} \leq 0$$

Transitionsraten  $q_{ij}$  werden einer Matrix  $\mathbf{Q}$  zusammengefasst

Eigenschaften von  $\mathbf{Q}$ :

- Zeilensumme 0
- Nicht negative Elemente außerhalb der Diagonalen

Verhalten des Markov-Prozesses im Zustand  $i$ :

- Die Verweilzeit im Zustand ist exponentiell verteilt mit Rate  $-q_{ii}$
- Beim Verlassen des Zustandes geht der Prozess mit Wahrscheinlichkeit  $q_{ij} / -q_{ii}$  in Zustand  $j$  über

Eingebetteter zeitdiskreter Markov-Prozess der Übergangswahrscheinlichkeiten:

- Zustandsübergangswahrscheinlichkeiten  $s_{ij} = q_{ij} / -q_{ii}$  für  $i \neq j$  und  $s_{ii} = 0$

- Matrix  $\mathbf{S}$  des eingebetteten diskreten Markov-Prozesses  $\mathbf{Y}$

$Y_k$  ist der Zustand nach der  $k$ -ten Transition

Verweilzeit im Zustand wird nicht beachtet

Ein kleines Beispiel (Wetter in Dortmund in kontinuierlicher Zeit)

Zustandsraum  $S = \{1, 2, 3\}$

$x = 1$ : Regen

$x = 2$ : Bedeckt

$x = 3$ : Sonnig

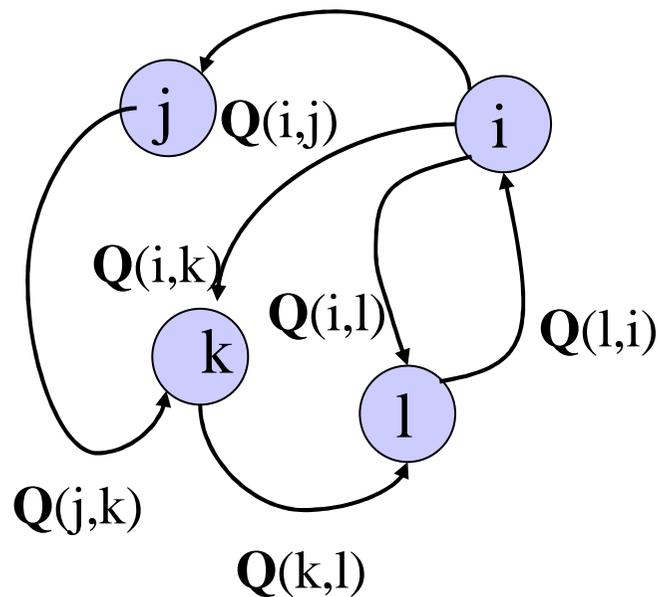
$$Q = \begin{pmatrix} \begin{matrix} \img alt="rain cloud" data-bbox="565 185 605 235"/> & \begin{matrix} \img alt="cloud" data-bbox="635 185 675 235"/> & \begin{matrix} \img alt="sun" data-bbox="700 185 735 235"/> \end{matrix} \end{matrix} \\ \begin{matrix} -0.6 & 0.3 & 0.3 \end{matrix} \\ \begin{matrix} 0.2 & -0.5 & 0.3 \end{matrix} \\ \begin{matrix} 0.2 & 0.2 & -0.4 \end{matrix} \end{pmatrix} \begin{matrix} \img alt="rain cloud" data-bbox="775 235 815 285"/> \\ \img alt="cloud" data-bbox="775 285 815 335"/> \\ \img alt="sun" data-bbox="775 335 815 375"/> \end{matrix}$$

Interpretation: Wenn es bedeckt ist, wird es eine exponentiell verteilte Zeit mit Rate 0.5 bedeckt bleiben (im Mittel also 2 Tage), dann folgt mit Wahrscheinlichkeit 0.4 ein Regentag und mit Wahrscheinlichkeit 0.6 ein Sonnentag

Eingebetteter Markov-Prozess  $S = \begin{pmatrix} 0 & 0.5 & 0.5 \\ 0.4 & 0 & 0.6 \\ 0.5 & 0.5 & 0 \end{pmatrix}$

Interpretation der transienten oder stationären Verteilung des eingebetteten Markov-Prozesses!?

Wie im zeitdiskreten Fall können zeitkontinuierliche Markov-Prozesse mittels gerichteter bewerteter Graphen dargestellt werden



Mit Hilfe des Graphen werden definiert:

- Erreichbarkeit – Unerreichbarkeit von Zuständen
- Abgeschlossene und irreduzible Zustandsmengen

Weitere Eigenschaften können aus dem eingebetteten zeitdiskreten Markov-Prozess abgeleitet werden:

- Rekurrenz von Zuständen:  $i$  im eingebetteten Prozess rekurrent  $\Rightarrow$   
 $i$  im zeitkontinuierlichen Prozess rekurrent
- Vorsicht: positive Rekurrenz und Nullrekurrenz übertragen sich genauso wenig wie Periodizität

Wie im zeitdiskreten Fall wird das Verhalten des Markov-Prozesses auch im zeitkontinuierlichen Fall durch die Chapman-Kolmogorov Gleichungen beschrieben

Es gilt dann für homogen Markov-Prozesse gilt:

$$p_{ij}(\tau) = \sum_k p_{ik}(\tau - \alpha) p_{kj}(\alpha) \quad \text{für } 0 \leq \alpha \leq \tau$$

$$\begin{aligned} p_{ij}(t + \Delta) - p_{ij}(t) &= \sum_k p_{ik}(t + \Delta - \alpha) p_{kj}(\alpha) - \sum_k p_{ik}(t - \alpha) p_{kj}(\alpha) \\ &= \sum_k (p_{ik}(t + \Delta - \alpha) - p_{ik}(t - \alpha)) p_{kj}(\alpha) \end{aligned}$$

Wenn beide Seiten durch  $\Delta$  dividiert werden und  $\Delta \rightarrow 0$ ,  $\alpha \rightarrow t$  betrachtet wird, so ergeben sich

Chapman-Kolmogorov Vorwärtsgleichungen: 
$$\frac{dp_{ij}(t)}{dt} = \sum_k q_{kj} p_{ik}(t)$$

Chapman-Kolmogorov Rückwärtsgleichungen: 
$$\frac{dp_{ij}(t)}{dt} = \sum_k q_{ik} p_{kj}(t)$$

Sei  $\boldsymbol{\pi}(t)$  der Vektor der Zustandswahrscheinlichkeiten zum Zeitpunkt  $t$

$$\pi_i(t + \Delta) = \pi_i(t) \left( 1 - \sum_{j \neq i} q_{ij} \Delta \right) + \left( \sum_{k \neq i} q_{ki} \pi_k(t) \right) \Delta + o(\Delta)$$

Da die Diagonalelemente von  $\mathbf{Q}$  die negative Zeilensumme beinhalten gilt auch

$$\pi_i(t + \Delta) = \pi_i(t) + \left( \sum_k q_{ki} \pi_k(t) \right) \Delta + o(\Delta)$$

und folgende Grenzwertbetrachtung

$$\lim_{\Delta \rightarrow 0} \left( \frac{\pi_i(t + \Delta) - \pi_i(t)}{\Delta} \right) = \lim_{\Delta \rightarrow 0} \left( \sum_k q_{ki} \pi_k(t) + \frac{o(\Delta)}{\Delta} \right)$$

$$\text{d.h. } \frac{d\pi_i(t)}{dt} = \sum_k q_{ki} \pi_k(t) \Rightarrow \frac{d\boldsymbol{\pi}(t)}{dt} = \boldsymbol{\pi}(t) \mathbf{Q}$$

Im stationären Fall ändert sich die Wahrscheinlichkeitsverteilung nicht mehr, d.h. die Ableitung wird  $\mathbf{0}$ .

## Q5.2 Vom Modell zum Markov-Prozess

Beschreibung der Modelle üblicherweise in einem Modellierungsformalismus

⇒ Ableitung des Markov-Prozesses

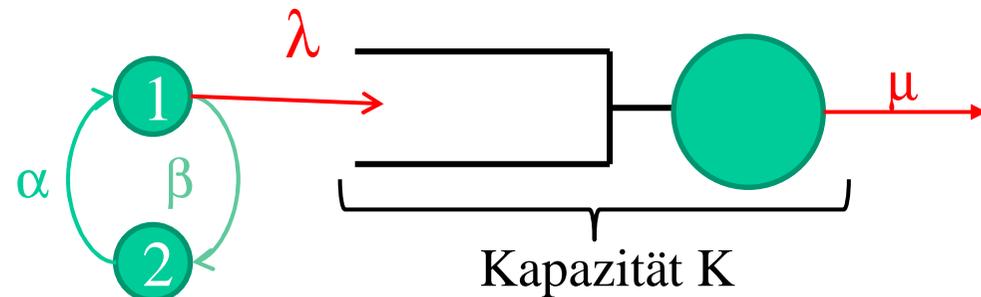
Unterscheidung zeitdiskrete und zeitkontinuierliche Modelle:

- In zeitdiskreten Modellen mit parallelen Aktivitäten, können alle Kombinationen parallel aktivierter Transitionen auftreten
- In zeitkontinuierlichen Modellen treten Ereignisse einzeln auf

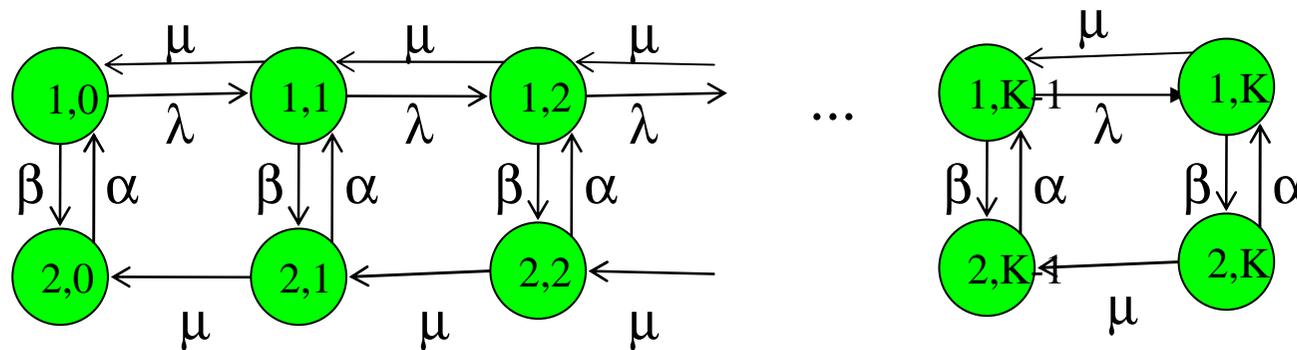
Wir betrachten als Beispiele:

- Warteschlangennetze
- Stochastische Petri-Netze
- Stochastische Prozessalgebren

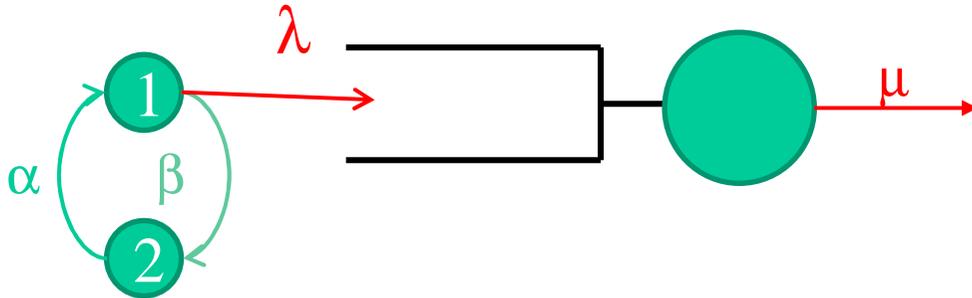
Warteschlangennetz: Station mit unterbrochenem Poisson-Ankunftsprozess  
(vgl. zeitdiskretes Modell in Q4)



Zustandsraum:  $S = \{(1,0),(2,0),(1,1), \dots,(1,K),(2,K)\}$



## Leistungsmaße in Warteschlangennetzen:

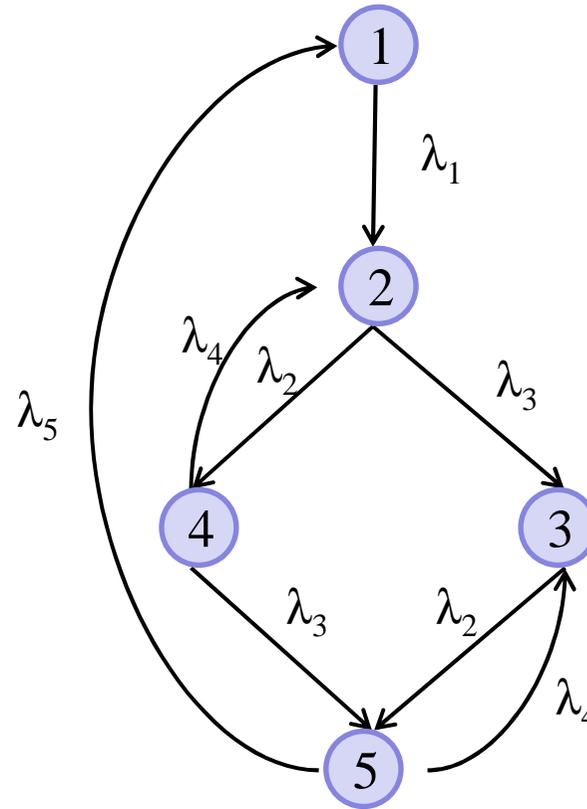
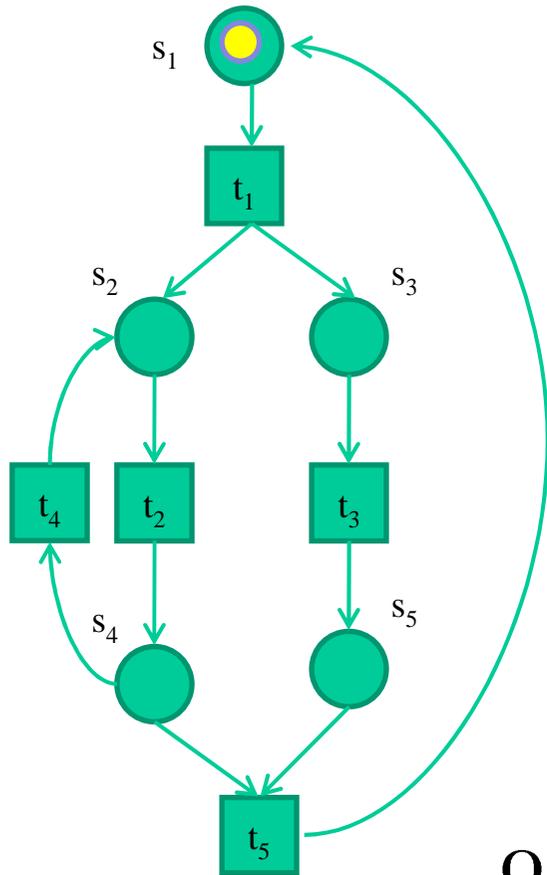


Stationäre Maße werden mit Hilfe des stationären Vektors  $\boldsymbol{\pi}$  berechnet  
(transiente Maße mit Hilfe des transienten Vektors  $\boldsymbol{\pi}(t)$ )

Beispiele:

- Mittlere Population im Puffer  $\sum_{k=1 \dots K} k(\boldsymbol{\pi}_{1,k} + \boldsymbol{\pi}_{2,k})$
- Auslastung des Bedieners  $\sum_{k=1 \dots K} (\boldsymbol{\pi}_{1,k} + \boldsymbol{\pi}_{2,k})$
- Durchsatz  $\sum_{k=1 \dots K} \mu(\boldsymbol{\pi}_{1,k} + \boldsymbol{\pi}_{2,k})$

# Stochastische Petri-Netze



Feuerungsrate  $t_i = \lambda_i$

$$Q = \begin{pmatrix} -\lambda_1 & \lambda_1 & 0 & 0 & 0 \\ 0 & -\lambda_2 - \lambda_3 & \lambda_3 & \lambda_4 & 0 \\ 0 & 0 & -\lambda_2 & 0 & \lambda_2 \\ 0 & \lambda_4 & 0 & -\lambda_3 - \lambda_4 & \lambda_3 \\ \lambda_5 & 0 & \lambda_4 & 0 & -\lambda_4 - \lambda_5 \end{pmatrix}$$

$$S = \{s_1, s_2s_3, s_2s_5, s_3s_4, s_4s_5\} = \{1, 2, 3, 4, 5\}$$

# Stochastische Prozessalgebren

$$P_{11} = (\text{think}, \lambda_1).P_{12}$$

$$P_{12} = (\text{get}_1, \alpha_1).P_{13}$$

$$P_{13} = (\text{work}, \mu_1).P_{14}$$

$$P_{14} = (\text{rel}_1, \beta_1).P_{11}$$

$$P_{21} = (\text{think}, \lambda_2).P_{22}$$

$$P_{22} = (\text{get}_2, \alpha_2).P_{23}$$

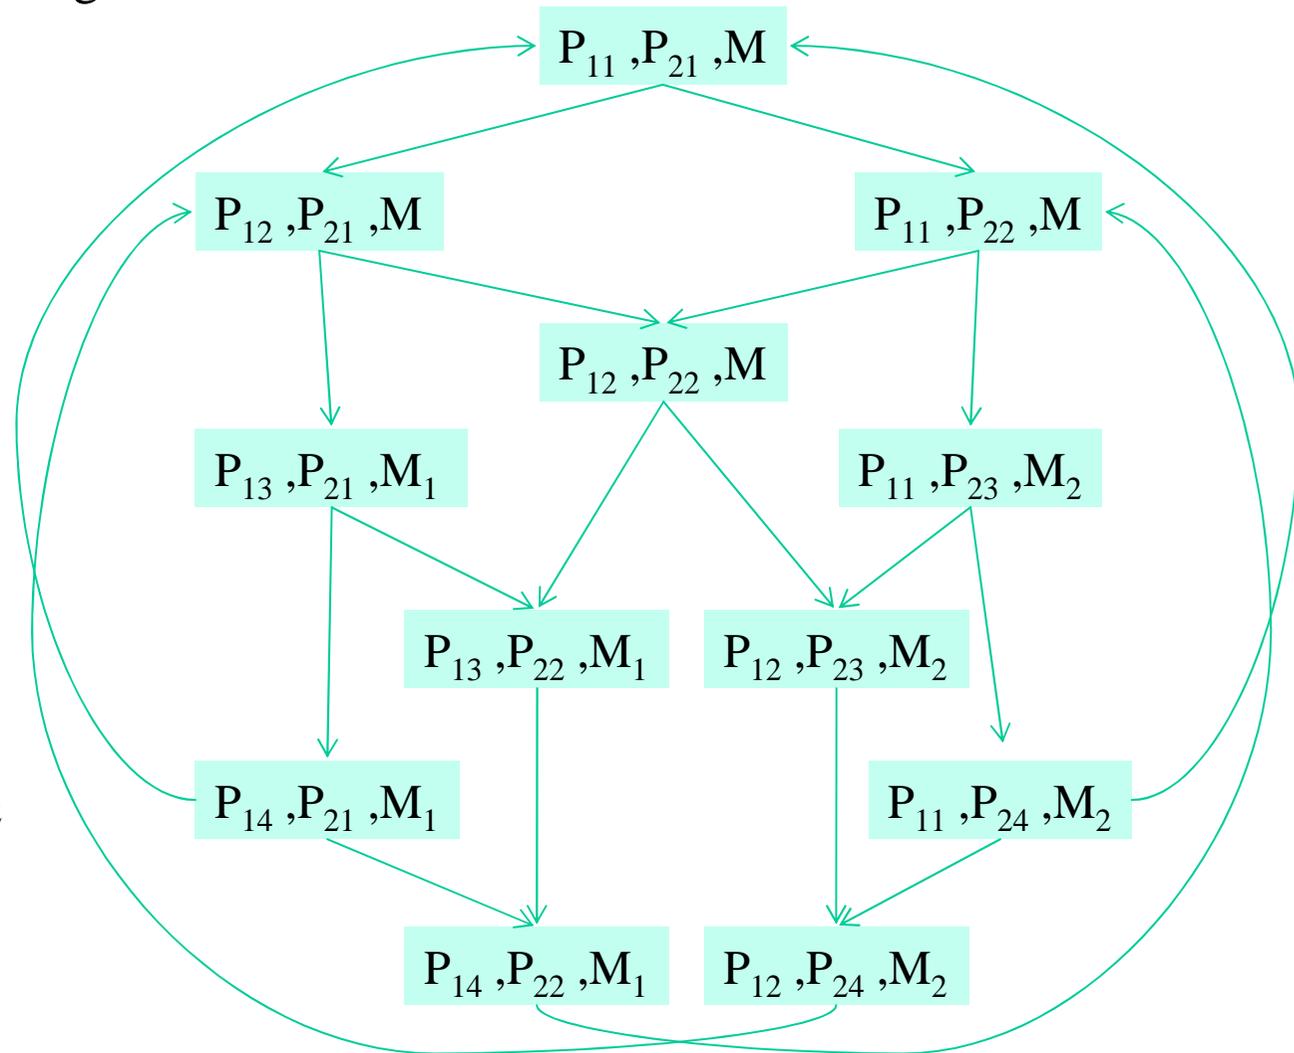
$$P_{23} = (\text{work}, \mu_2).P_{24}$$

$$P_{24} = (\text{rel}_2, \beta_2).P_{21}$$

$$M = (\text{get}_1, \top).M_1 + (\text{get}_2, \top).M_2$$

$$M_1 = (\text{rel}, \top).M$$

$$M_2 = (\text{rel}, \top).M$$

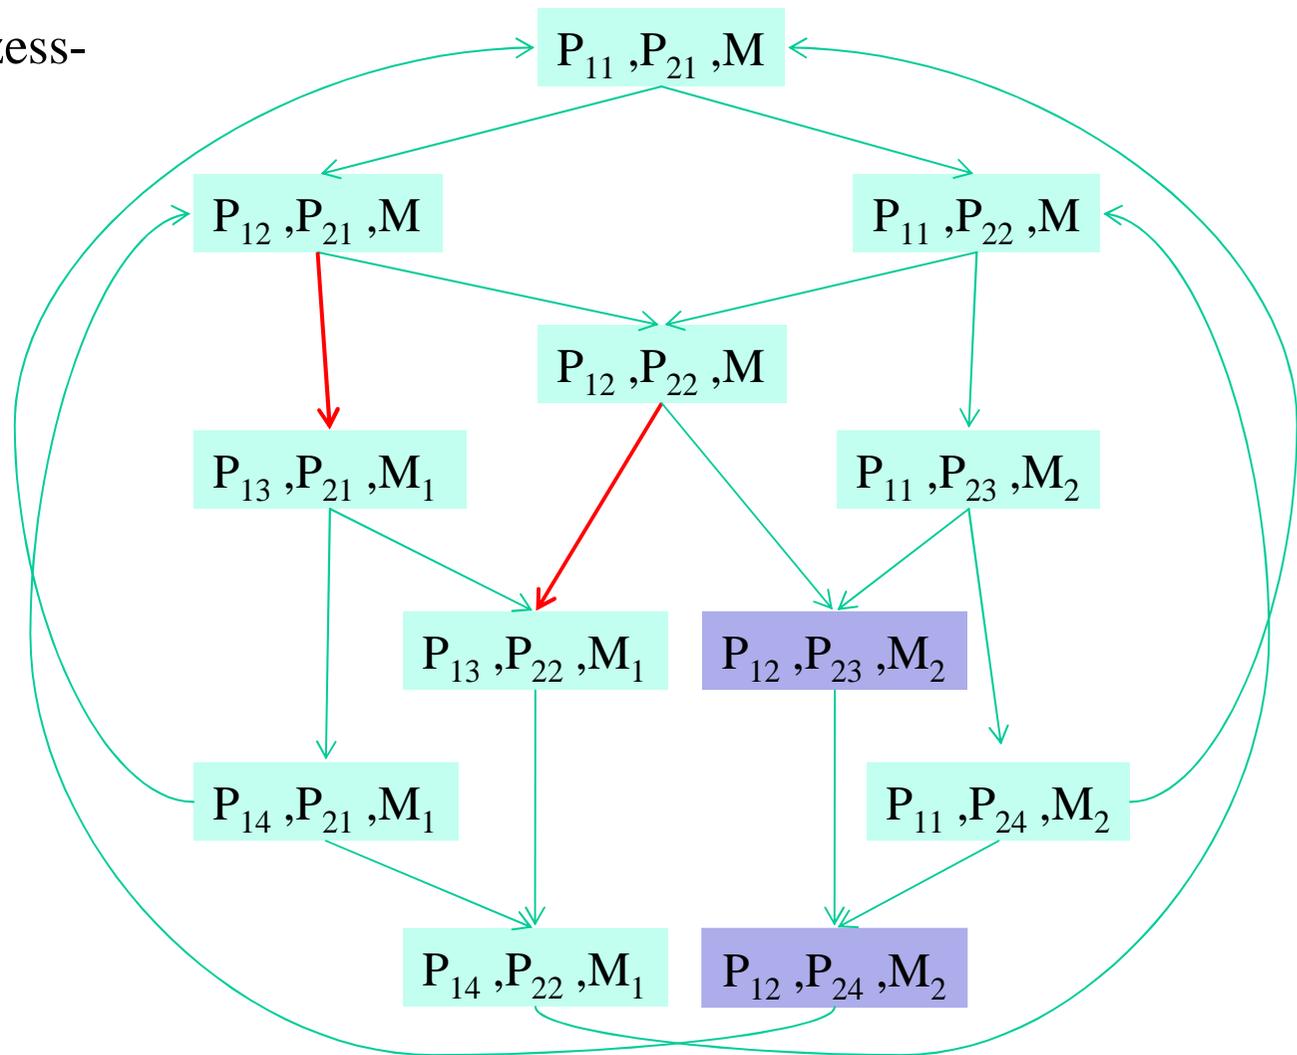


Leistungsmaße in Prozess-  
Algebren:

- Definition über Zustände von Komponenten oder
- Transitionsbeschriftungen

Beispiel

- Zustand  $P_{12}$  und Ressource  $M_2$
- Durchsatz der mit  $get_1$  beschrifteten Transitionen



## Q5.3 Stationäre Analyse

Ziel ist die Bestimmung von  $\lim_{t \rightarrow \infty} \boldsymbol{\pi}(t)$

Falls der Markov-Prozess stationär ist, gilt  $\lim_{t \rightarrow \infty} \boldsymbol{\pi}(t) = \boldsymbol{\pi}$

d.h. der Grenzwert konvergiert gegen einen eindeutigen Vektor

Unter Nutzung der Chapman-Kolmogorov Gleichungen gilt dann:

$$\frac{d\boldsymbol{\pi}}{dt} = \boldsymbol{\pi} \mathbf{Q} = \mathbf{0} \text{ und } \sum_i \pi_i = 1$$

Bleiben folgende Fragen:

- Wann existiert eine eindeutige stationäre Verteilung?
- Wann ist die stationäre Verteilung unabhängig von  $\boldsymbol{\pi}(0)$ ?
- Wie berechnet man die stationäre Verteilung?
- Gibt es einen Zusammenhang zwischen der stationären Verteilung des zeitkontinuierlichen Markov-Prozesses und des eingebetteten zeitdiskreten Markov-Prozesses?

### Existenz der stationären Verteilung:

- Für einen endlichen irreduziblen zeitkontinuierlichen Markov-Prozess existiert eine eindeutige stationäre Verteilung, diese ist unabhängig von  $\pi(0)$ .
- Für einen unendlichen irreduziblen zeitkontinuierlichen Markov-Prozess in dem alle Zustände positiv rekurrent sind, existiert eine eindeutige stationäre Verteilung, diese ist unabhängig von  $\pi(0)$ .
- Für einen Markov-Prozess dessen Zustandsraum  $S$  sich in Untermengen  $S_t$ ,  $S_{r1}$ , ...,  $S_{rK}$  disjunkt unterteilen lässt, so dass
  - $S_t$  nur transiente Zustände beinhaltet
  - alle  $S_{r_i}$  irreduzible Zustandsmengen sind, in denen alle Zustände positiv rekurrent sind

kann eine eindeutige stationäre Verteilung berechnet werden, die von  $\pi(0)$  abhängt

Bedingungen wie im zeitdiskreten Fall ohne Periodizität!

Berechnung der stationären Verteilung:

Lösung eines linearen Gleichungssystems

➤ Für endliche Zustandsräume Standard

aber Zustandsräume können sehr groß werden (Millionen, Milliarden, ...)

➤ Im endlichen Fall nur bei spezieller Struktur lösbar (rekursive Berechnung)

Wir beschränken uns erst einmal auf den endlichen Fall

$$\mathbf{Q} = \begin{pmatrix} \begin{matrix} \img alt="rain cloud" data-bbox="211 471 248 523" & \img alt="cloud" data-bbox="279 466 316 514" & \img alt="sun" data-bbox="347 473 378 514" \\ -0.6 & 0.3 & 0.3 \\ 0.2 & -0.5 & 0.3 \\ 0.2 & 0.2 & -0.4 \end{matrix} \end{pmatrix} \begin{matrix} \img alt="rain cloud" data-bbox="425 521 462 573" \\ \img alt="cloud" data-bbox="425 573 462 625" \\ \img alt="sun" data-bbox="425 625 462 656" \end{matrix} \begin{matrix} 0 = -0.6\pi_1 + 0.3\pi_2 + 0.3\pi_3 \\ 0 = 0.2\pi_1 - 0.5\pi_2 + 0.3\pi_3 \\ 0 = 0.2\pi_1 + 0.2\pi_2 - 0.4\pi_3 \\ 1 = \pi_1 + \pi_2 + \pi_3 \end{matrix}$$

Eine der ersten drei Gleichungen ist redundant!

Resultat lautet  $\pi = (0.25, 0.3214, 0.4286)$

Berechnung der stationären Lösung:

➤ Direktes Lösungsverfahren auf Basis der Gauß-Elimination (und Varianten)

Aufwand: Speicher  $O(n^2)$  Zeit  $O(n^3)$

➤ Iteratives Lösungsverfahren berechnet konsekutive Approximationen

Aufwand: Speicher  $O(nz)$  ( $nz$ : Nichtnullelemente in  $\mathbf{Q}$ ), Zeit ??

Beispiel: Power-Methode

Sei  $\alpha \geq \max_i |\mathbf{Q}_{i,i}|$  und  $\mathbf{P} = \mathbf{Q}/\alpha + \mathbf{I}$  ( $\mathbf{P}$  ist eine stochastische Matrix!)

Berechne  $\lim_{k \rightarrow \infty} \boldsymbol{\pi}(k) = \boldsymbol{\pi}(k-1)\mathbf{P}$  konvergiert gegen  $\boldsymbol{\pi}$ , falls  $\mathbf{P}$  aperiodisch

Beispiel:  $\mathbf{Q} = \begin{pmatrix} -0.6 & 0.3 & 0.3 \\ 0.2 & -0.5 & 0.3 \\ 0.2 & 0.2 & -0.4 \end{pmatrix} \Rightarrow \mathbf{P} = \begin{pmatrix} 0 & 1/2 & 1/2 \\ 1/3 & 1/6 & 1/2 \\ 1/3 & 1/3 & 1/3 \end{pmatrix}$

Für  $\alpha=0.6$

Power-Methode konvergiert oft sehr langsam, es gibt bessere iterative Methoden!

Zusammenhang zwischen der stationären Verteilung des zeitkontinuierlichen Markov-Prozesses mit Matrix  $\mathbf{Q}$  und des eingebetteten zeitdiskreten Markov-Prozesses mit Matrix  $\mathbf{S}$  für endliche Zustandsräume

➤  $\mathbf{Q}$  irreduzibel  $\Leftrightarrow \mathbf{S}$  irreduzibel ( $\mathbf{S}$  sei zusätzlich aperiodisch)

➤ Sei  $\boldsymbol{\pi}$  stationäre Verteilung von  $\mathbf{Q}$  und  $\boldsymbol{\theta}$  stationäre Verteilung von  $\mathbf{S}$

Es gilt  $\pi_i = \theta_i / (-\mathbf{Q}_{i,i} (\sum_j \theta_j / -\mathbf{Q}_{j,j})^{-1})$

$$\mathbf{Q} = \begin{pmatrix} \begin{matrix} \img alt="rain cloud" data-bbox="212 444 248 494"/> & \begin{matrix} \img alt="cloud" data-bbox="281 438 317 488"/> & \begin{matrix} \img alt="sun" data-bbox="348 444 378 484"/> \end{matrix} \\ -0.6 & 0.3 & 0.3 \end{matrix} \\ \begin{matrix} \img alt="rain cloud" data-bbox="426 491 462 541"/> \\ \begin{matrix} \img alt="cloud" data-bbox="426 541 462 591"/> \\ \begin{matrix} \img alt="sun" data-bbox="426 591 462 631"/> \end{matrix} \end{matrix} \end{pmatrix} \quad \mathbf{S} = \begin{pmatrix} \begin{matrix} \img alt="rain cloud" data-bbox="566 434 602 484"/> & \begin{matrix} \img alt="cloud" data-bbox="636 428 672 478"/> & \begin{matrix} \img alt="sun" data-bbox="702 434 732 474"/> \end{matrix} \\ 0 & 0.5 & 0.5 \end{matrix} \\ \begin{matrix} \img alt="rain cloud" data-bbox="778 481 814 531"/> \\ \begin{matrix} \img alt="cloud" data-bbox="778 531 814 581"/> \\ \begin{matrix} \img alt="sun" data-bbox="778 581 814 621"/> \end{matrix} \end{matrix} \end{pmatrix}$$

$$\boldsymbol{\pi} = (0.25, 0.3214, 0.4286)$$

$$\boldsymbol{\theta} = (0.3111, 0.3333, 0.3556)$$

## Q5. 4 Transiente Analyse

Berechnung von  $\boldsymbol{\pi}(t)$  in Abhängigkeit von  $\boldsymbol{\pi}(0)$

Es gilt  $\pi_i(t) = \sum_j \pi_j(0)P[X(t)=i | X(0) = j] = \sum_j \pi_j(0)p_{ji}(t)$

In Matrixform  $\boldsymbol{\pi}(t) = \boldsymbol{\pi}(0)\mathbf{P}(t)$  mit der Lösung  $\boldsymbol{\pi}(t) = \boldsymbol{\pi}(0)e^{\mathbf{Q}t}$

Approximation durch Taylor-Reihe  $e^{\mathbf{Q}t} = \sum_{k=0}^{\infty} \frac{(\mathbf{Q}t)^k}{k!}$

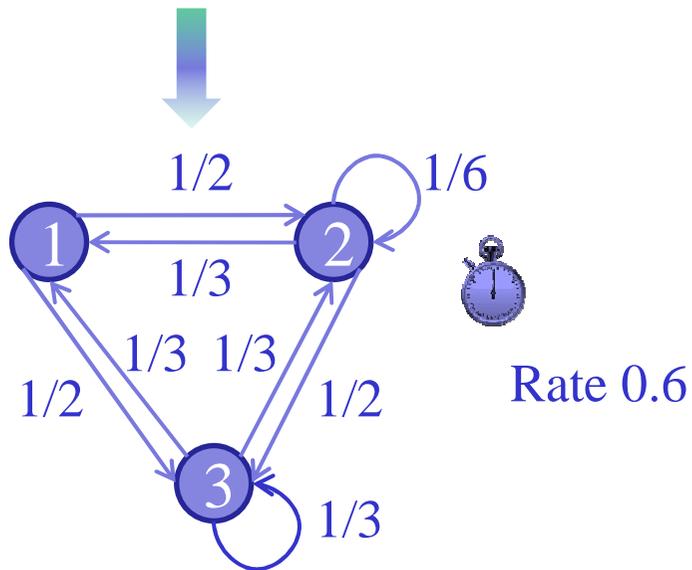
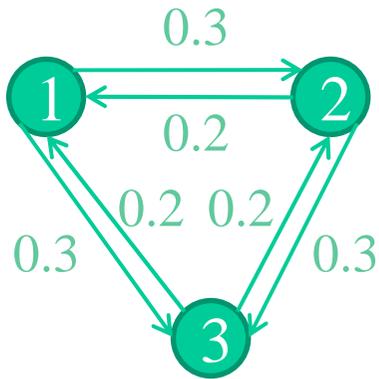
Damit gilt:  $\boldsymbol{\pi}(t) \approx \boldsymbol{\pi}(0) \sum_{k=0}^K \frac{(\mathbf{Q}t)^k}{k!}$

$$\mathbf{Q} = \begin{pmatrix} -0.6 & 0.3 & 0.3 \\ 0.2 & -0.5 & 0.3 \\ 0.2 & 0.2 & -0.4 \end{pmatrix} \Rightarrow \mathbf{P}(2.0) \approx \begin{pmatrix} 0.401 & 0.276 & 0.323 \\ 0.200 & 0.478 & 0.323 \\ 0.200 & 0.231 & 0.569 \end{pmatrix}$$

Berechnung u.U. in mehreren Schritten  $\boldsymbol{\pi}(0), \boldsymbol{\pi}(t_1), \dots, \boldsymbol{\pi}(t_L) = \boldsymbol{\pi}(t)$

# Alternative Methode: Randomisierung/Uniformisierung

Zeitkontinuierlicher Markov-Prozess

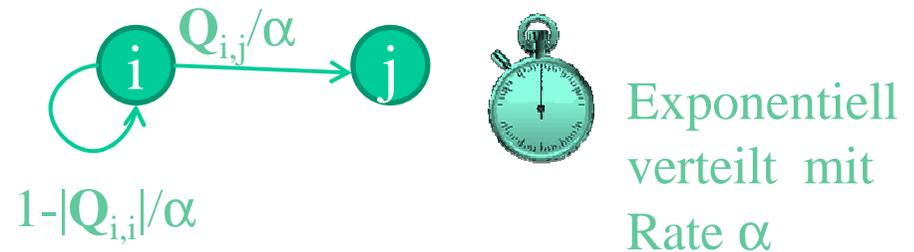


© Peter Buchholz 2008

Einführung eines Weckers mit exponentiell verteilten Zeiten mit Rate  $\alpha \geq \max_i |Q_{i,i}|$

Falls der Prozess im Zustand  $i$  ist und der Wecker abläuft, so akzeptiere Ereignis mit Wahrscheinlichkeit  $|Q_{i,i}| / \alpha$

$\Rightarrow$  Zeit bis zum nächsten Ereignis exponentiell verteilt mit Rate  $|Q_{i,i}|$



## Transformation des zeitkontinuierlichen Prozesses in einen zeitdiskreten Prozess + einen Poisson-Prozess

$$\mathbf{Q} \Rightarrow \mathbf{P} = \mathbf{Q}/\alpha + \mathbf{I} \text{ (stochastische Matrix)}$$

$$\text{Es gilt dann } \pi(t) = \pi(0) \sum_{k=0}^{\infty} e^{-\alpha t} \frac{(\alpha t)^k}{k!} \mathbf{P}^k$$

Vorteil gegenüber Taylor-Reihe, keine negativen Werte und Berechnung von  
Fehlerschranken möglich

$$\pi(0) \sum_{k=0}^K e^{-\alpha t} \frac{(\alpha t)^k}{k!} \mathbf{P}^k \leq \pi(t) \leq \pi(0) \sum_{k=0}^K e^{-\alpha t} \frac{(\alpha t)^k}{k!} \mathbf{P}^k + \epsilon \mathbf{e}$$

$$\text{mit } \epsilon = 1 - \sum_{k=0}^K e^{-\alpha t} \frac{(\alpha t)^k}{k!}$$

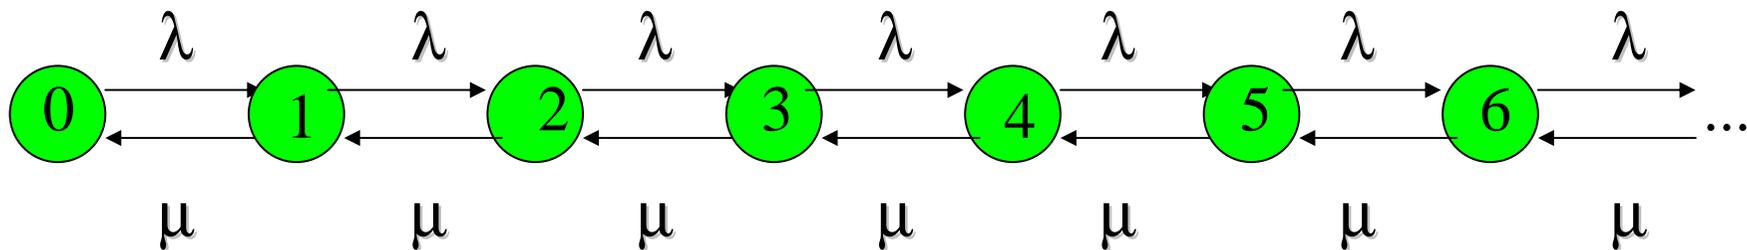
## Q5.5 Stationäre Analyse von Modellen mit unendlichem Zustandsraum

Lösung eines Gleichungssystems mit unendlich vielen Variablen

⇒ Nur in speziellen Fällen möglich, wenn eine rekursive Struktur vorliegt

Beispiel: Geburts-/Todesprozess

(hier zeitkontinuierlich, zeitdiskret analog zu behandeln)

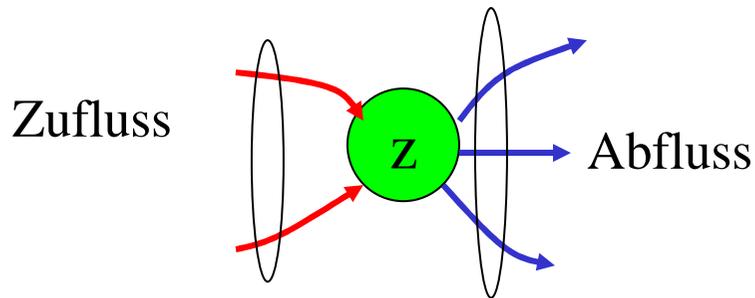


Sei  $\rho = \lambda / \mu$

# Basis der stationären Analyse von Markov-Prozessen

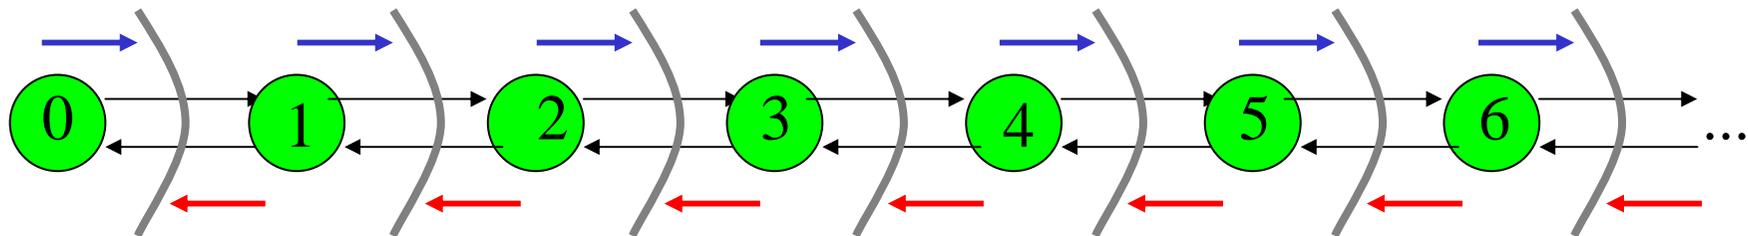
Wahrscheinlichkeitsfluss:  $W.$  im Zustand zu sein  $\cdot$  Transitionsrate  
Im stationären Zustand ändert sich die  
Wahrscheinlichkeitsverteilung nicht  $\Rightarrow$

Fluss aus einem Zustand = Fluss in den Zustand



$\Rightarrow$  Berechnung der stationären  
Wahrscheinlichkeiten lässt sich  
auf Lösung eines linearen  
Gleichungssystems mit  
rekursiver Struktur reduzieren

Geburts-/Todes-Prozess:



Flussgleichgewicht über jeden Schnitt!

## Resultierendes Gleichungssystem

$$\pi_i \cdot \lambda = p_{i+1} \cdot \mu \Rightarrow \pi_i = \pi_0 \left( \frac{\lambda}{\mu} \right)^i = \rho^i$$

- Falls wir  $\pi_0$  kennen, können wir alle  $\pi_i$  berechnen

Überlegungen zur Berechnung von  $\pi_0$ :

$\pi_i$  ( $i = 0, \dots, \infty$ ) definieren eine Wahrscheinlichkeitsverteilung

$\Rightarrow$  Summe der  $\pi_i$  muss 1.0 ergeben

Damit gilt: 
$$\sum_{i=0}^{\infty} \pi_i = \pi_0 \sum_{i=0}^{\infty} \rho^i \Rightarrow \pi_0 = \frac{1}{\sum_{i=0}^{\infty} \rho^i}$$

Vorausgesetzt die Reihensumme ist endlich!

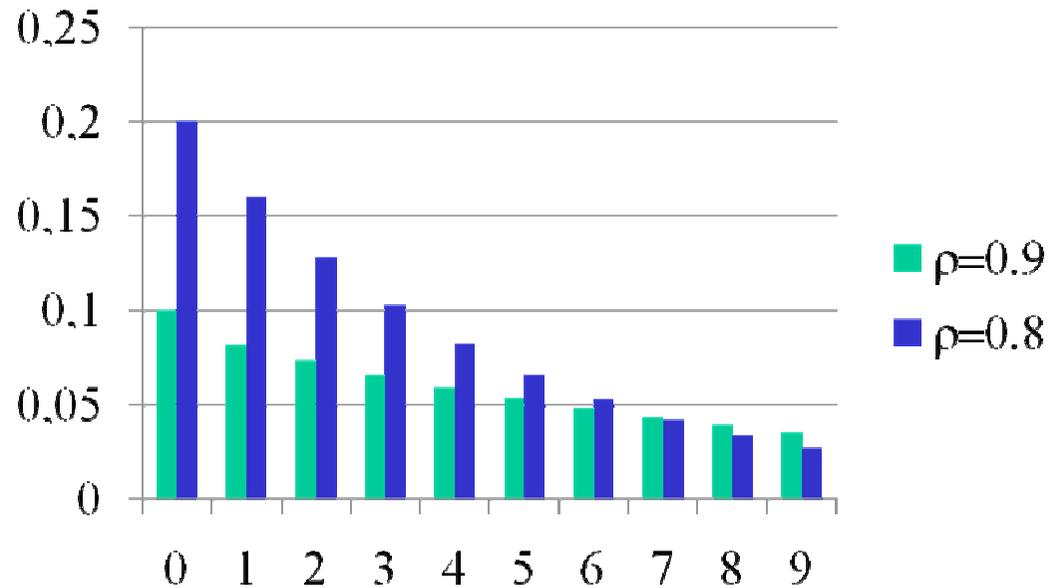
Geometrische Reihe: 
$$\sum_{i=0}^{\infty} \rho^i = (1 - \rho)^{-1} \quad \text{falls } \rho < 1$$

Falls  $\rho \geq 1$  werden alle Zustände nullrekurrent

$\Rightarrow$  alle Zustandswahrscheinlichkeiten werden 0

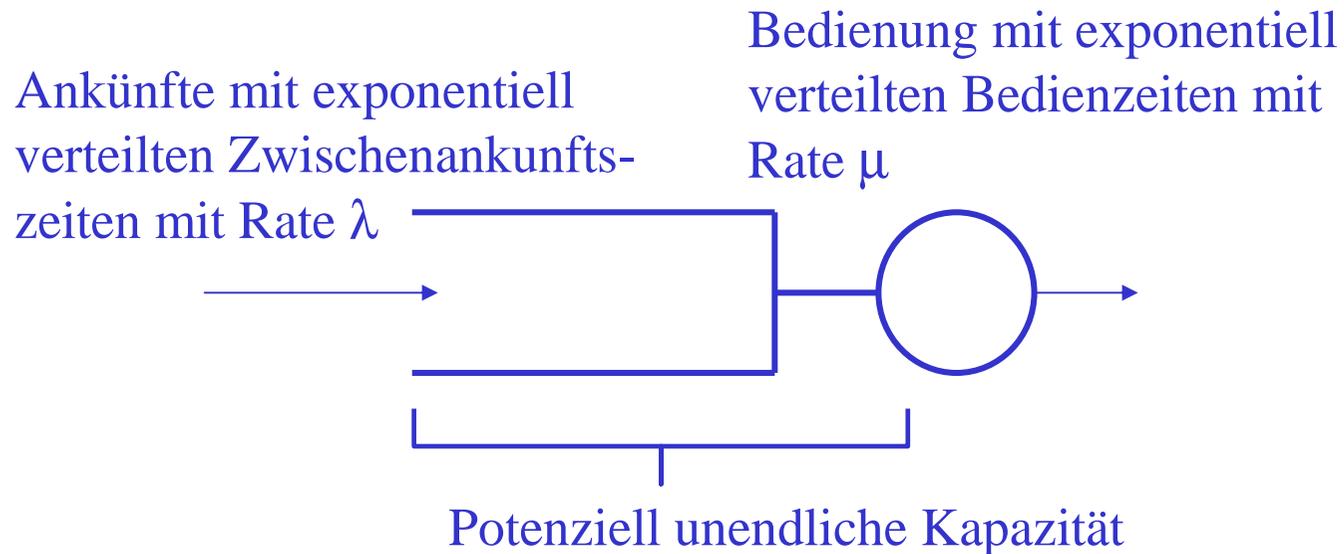
Prozess driftet nach rechts (gegen unendlich)

Für  $\rho < 1$  geometrisch fallende Zustandswahrscheinlichkeiten



## Interpretation als einfache Warteschlange

(Details zur Modellklasse im nächsten Kapitel)



Typische Fragestellungen:

➤ Wie viele Kunden warten im Mittel?

(Population  $N$  (inkl. Bediner) bzw.  $N_w$  (exkl. Bediener))

➤ Wie viele Kunden werden im Durchschnitt pro Zeiteinheit bedient? (Durchsatz  $X$ )

➤ Wie lange wartet ein Kunde im Mittel? (Wartezeit  $W$ )

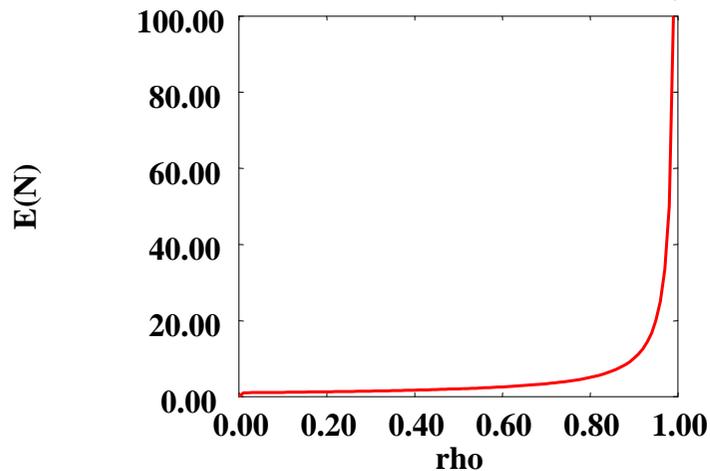
( $N$ ,  $N_w$ ,  $X$ ,  $W$  sind Zufallsvariablen, wir berechnen Erwartungswerte!)

Auslastung:  $\rho = 1 - \pi_0$

Durchsatz  $E(X) = \lambda$

$$\begin{aligned} \text{Mittlere Population: } E(N) &= \sum_{i=0}^{\infty} i \cdot \pi_i &= (1 - \rho) \sum_{i=1}^{\infty} i \cdot \rho^i \\ &= (1 - \rho) \rho \frac{d}{d\rho} \sum_{i=0}^{\infty} \rho^i &= (1 - \rho) \rho \frac{d}{d\rho} \frac{1}{1 - \rho} \\ &= (1 - \rho) \rho \frac{1}{(1 - \rho)^2} &= \frac{\rho}{1 - \rho} \end{aligned}$$

$$\begin{aligned} \text{Mittlere Population: } E(N_w) &= \sum_{i=0}^{\infty} (i - 1) \cdot \pi_i &= (1 - \rho) \rho \sum_{i=1}^{\infty} i \cdot \rho^i \\ \text{(nur Warteraum)} & & \\ &= \rho E(N) &= \frac{\rho^2}{1 - \rho} \end{aligned}$$



Verweilzeiten später siehe Q6.1

## Verallgemeinerung der Ideen

Zur Erinnerung:

Sei  $\mathbf{Q}$  irreduzible Matrix eines zeitkontinuierlichen Markov-Prozesses

Sei  $\alpha \geq \max_i |\mathbf{Q}_{ii}|$  ( $\alpha < \infty$ ) und  $\mathbf{P} = \mathbf{Q}/\alpha + \mathbf{I}$

Sei  $\mathbf{P}$  aperiodisch (immer erreichbar durch Wahl von  $\alpha > \max_i |\mathbf{Q}_{ii}|$ )

Es gilt dann für Vektor  $\boldsymbol{\pi}$  mit  $\sum_i \pi_i = 1$ :  $\boldsymbol{\pi}\mathbf{Q} = \mathbf{0} \Leftrightarrow \boldsymbol{\pi}\mathbf{P} = \boldsymbol{\pi}$

$\Rightarrow$  Wir können mit  $\mathbf{Q}$  oder  $\mathbf{P}$  arbeiten

(und nutzen im Folgenden  $\mathbf{P}$ )

Ziel: Herausarbeiten von Strukturen, die es erlauben auch bei unendlichen Zustandsmengen  $\boldsymbol{\pi}$  zu berechnen

Bisher behandelte Matrixstruktur (siehe M/M/1-System)

Geburts-/Todesprozess:

$$\mathbf{P} = \begin{pmatrix} 1 - p_{00} & p_{01} & & & \\ p_{10} & 1 - p_{10} - p_{12} & & & \\ & p_{21} & 1 - p_{21} - p_{23} & p_{23} & \\ & \ddots & \ddots & \ddots & \\ & & & & \ddots \end{pmatrix}$$

Mit der rekursiven Berechnung:

$$\pi_{i+1} = (p_{i+1i})^{-1} ((1 - p_{ii})\pi_i - p_{i-1i}\pi_{i-1}), \quad \pi_1 = (p_{10})^{-1}(1 - p_{00})\pi_0$$

Wenn  $\pi_0$  bekannt ist, so können alle  $\pi_i$  berechnet werden!

Möglicher Ansatz:

1. Setze  $\pi_0 = 1$
2. Berechne  $\pi_1, \dots, \pi_N$
3. Normalisiere den resultierenden Vektor

Auftretender Fehler  
proportional zu

$$\sum_{i=N+1}^{\infty} \pi_i / \sum_{i=0}^N \pi_i$$

## Verallgemeinerung obere Hessenberg-Matrix

$$\mathbf{P} = \begin{pmatrix} p_{00} & p_{01} & p_{02} & p_{03} & \cdots \\ p_{10} & p_{11} & p_{12} & p_{13} & \cdots \\ 0 & p_{21} & p_{22} & p_{23} & \cdots \\ 0 & 0 & p_{32} & p_{33} & \cdots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{pmatrix}$$

Mit der rekursiven Berechnung:

$$\pi_{i+1} = (p_{i+1i})^{-1} \left( (1 - p_{ii})\pi_i - \sum_{j=0}^{i-1} p_{ji}\pi_j \right), \quad \pi_1 = (p_{10})^{-1}(1 - p_{00})\pi_0$$

Rekursive Berechnung, wie auf vorheriger Folie!

## Geht es noch weiter?

Ja, wenn sich nicht einzelne Elemente, sondern ganze Untermatrizen wiederholen!

⇒ Matrix-Geometrische/Matrix-Analytische Methoden (hier nur erste Ansätze)

Matrix eines Quasi-Geburts-Todes-Prozesses (QBD):

$$Q = \begin{pmatrix} \mathbf{B}_1 & \mathbf{B}_0 & \mathbf{0} & \mathbf{0} & \mathbf{0} & \cdots \\ \mathbf{B}_2 & \mathbf{A}_1 & \mathbf{A}_0 & \mathbf{0} & \mathbf{0} & \cdots \\ \mathbf{0} & \mathbf{A}_2 & \mathbf{A}_1 & \mathbf{A}_0 & \mathbf{0} & \cdots \\ \mathbf{0} & \mathbf{0} & \mathbf{A}_2 & \mathbf{A}_1 & \mathbf{A}_0 & \cdots \\ \vdots & \vdots & & \ddots & \ddots & \ddots \end{pmatrix}$$

Dimensionen der Matrizen

➤  $\mathbf{B}_1 : p \times p$

➤  $\mathbf{B}_0 : p \times m$

➤  $\mathbf{B}_2 : m \times p$

➤  $\mathbf{A}_0, \mathbf{A}_1$  und  $\mathbf{A}_2 : m \times m$

Es gilt (mit  $\mathbf{e}=(1,\dots,1)$ ,  $\mathbf{0}=(0,\dots,0)$ ):

➤  $\mathbf{B}_1 \mathbf{e}^T + \mathbf{B}_0 \mathbf{e}^T = \mathbf{0}^T$

➤  $\mathbf{B}_1 \mathbf{e}^T + (\mathbf{A}_0 + \mathbf{A}_1) \mathbf{e}^T = \mathbf{0}^T$

➤  $(\mathbf{A}_0 + \mathbf{A}_1 + \mathbf{A}_2) \mathbf{e}^T = \mathbf{0}^T$

Sei nun  $\boldsymbol{\pi} = (\boldsymbol{\pi}_0, \boldsymbol{\pi}_1, \dots)$  mit

➤  $\boldsymbol{\pi}_0$  Vektor der Länge  $p$

➤  $\boldsymbol{\pi}_i$  ( $i > 0$ ) Vektor der Länge  $m$

Ges. Vektor  $\boldsymbol{\pi}$  mit  $\boldsymbol{\pi}\mathbf{Q}=\mathbf{0}$  und  $\boldsymbol{\pi}\mathbf{e}^T = 1$ , sofern dieser existiert!

Wir nehmen an, dass  $\mathbf{Q}$  irreduzibel ist

Struktur der Matrix ähnelt Geburts-Todes-Prozess

wenn Skalare durch Matrizen ersetzt werden!

Lösung Geburts-Todes-Prozess:  $\boldsymbol{\pi}_i = \rho\boldsymbol{\pi}_{i-1} = \rho^i\boldsymbol{\pi}_0$  und  $\boldsymbol{\pi}_0 = 1 - \rho$

Geburts-Todes-Prozess  $\Rightarrow$  Quasi-Geburts-Todes-Prozess

Ersetze  $\rho$  durch Matrix  $\mathbf{R}$  der Dimension  $m \times m$  und

Prüfe, was passiert!

Erst einmal für  $j \geq 2$  (bei  $j=0$  oder  $1$  u.U. Dimensionsprobleme)

$$\pi_{j-1} \mathbf{A}_0 + \pi_j \mathbf{A}_1 + \pi_{j+1} \mathbf{A}_2 = \mathbf{0} \quad (*)$$

Wenn eine Matrix  $\mathbf{R}$  wie angenommen existiert so gilt für  $j \geq 2$ :

$$\pi_j = \pi_{j-1} \mathbf{R} \Rightarrow \pi_j = \pi_1 \mathbf{R}^{j-1}$$

Eingesetzt in (\*):

$$\pi_1 \mathbf{R}^{j-2} \mathbf{A}_0 + \pi_1 \mathbf{R}^{j-1} \mathbf{A}_1 + \pi_1 \mathbf{R}^j \mathbf{A}_2 = \mathbf{0} \quad \text{für alle } j \geq 2$$

Damit muss auch gelten:

$$\pi_1 \mathbf{R}^{j-2} (\mathbf{A}_0 + \mathbf{R} \mathbf{A}_1 + \mathbf{R}^2 \mathbf{A}_2) = \mathbf{0} \Rightarrow \mathbf{A}_0 + \mathbf{R} \mathbf{A}_1 + \mathbf{R}^2 \mathbf{A}_2 = \mathbf{0}$$

Quadratische Matrixgleichung zur Bestimmung von  $\mathbf{R}$

Damit  $\boldsymbol{\pi}$  existiert, muss gelten  $\boldsymbol{\pi}_1 \sum_{i=0, \dots} \mathbf{R}^i \mathbf{e}^T < \infty$

d.h. der Spektralradius von  $\mathbf{R}$  muss kleiner 1 sein!

Angenommen, wir hätten ein „passendes“  $\mathbf{R}$  gefunden,

dann muss noch  $\boldsymbol{\pi}_0$  berechnet werden!

$$\begin{aligned} \text{Es gilt:} \quad \pi_0 \mathbf{B}_1 + \pi_1 \mathbf{B}_2 &= \mathbf{0} \\ \pi_0 \mathbf{B}_0 + \pi_1 \mathbf{A}_1 + \pi_2 \mathbf{A}_2 &= \mathbf{0} \end{aligned}$$

Einsetzen von  $\pi_1 \mathbf{R}$  für  $\pi_2$  liefert:

$$(\pi_1, \pi_2) \begin{pmatrix} \mathbf{B}_1 & \mathbf{B}_0 \\ \mathbf{B}_2 & \mathbf{A}_1 + \mathbf{R} \mathbf{A}_2 \end{pmatrix} = \mathbf{0}$$

Lösung erfordert zusätzliche Normierungsbedingung (Summe der W. 1):

$$1 = \pi_0 \mathbf{e}^T + \pi_1 \sum_{j=0}^{\infty} \mathbf{R}^j \mathbf{e}^T = \pi_0 \mathbf{e}^T + \pi_1 (\mathbf{I} - \mathbf{R})^{-1} \mathbf{e}^T$$

Berechnung von  $\mathbf{R}$ :

Viele Verfahren existieren, wir schauen uns nur einen einfachen Algorithmus an

Matrix  $\mathbf{A}_1$  besitzt negative Diagonalelemente und  $\mathbf{A}_1 \mathbf{e}^T \leq \mathbf{0}$

Falls  $\mathbf{Q}$  irreduzibel ist, existiert  $(\mathbf{A}_1)^{-1}$

Damit können wir umformen:

$$\mathbf{0} = \mathbf{A}_0 + \mathbf{R}\mathbf{A}_1 + \mathbf{R}^2\mathbf{A}_2 \Rightarrow \mathbf{R} = - \left( \mathbf{A}_0 (\mathbf{A}_1)^{-1} + \mathbf{R}^2 \mathbf{A}_2 (\mathbf{A}_1)^{-1} \right)$$

Fixpunkt-Algorithmus, initialisiere  $\mathbf{R}[0]=0$  und iteriere

$$\mathbf{R}[k] = - \left( \mathbf{A}_0 (\mathbf{A}_1)^{-1} + (\mathbf{R}[k-1])^2 \mathbf{A}_2 (\mathbf{A}_1)^{-1} \right)$$

bis  $\|\mathbf{R}[k]-\mathbf{R}[k-1]\| < \varepsilon$

Verfahren konvergiert, aber u.U. sehr langsam!